



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA

Diseño de la red de la cadena de suministro de una marca de coches eléctricos para su entrada en Europa.

AUTOR: Pablo Fullana Fuster

DIRECTOR/ES:

Andrés Carrión García

Eva Vallada Regalado

**Máster Universitario en Ingeniería de
Análisis de Datos, Mejora de Procesos y Toma de Decisiones**

Valencia, noviembre de 2020

RESUMEN

Este trabajo resuelve una decisión de negocio fundamental para un fabricante de vehículos eléctricos, que busca optimizar el Diseño de su Red en la Cadena de Suministro. Para ello, se emplean la optimización matemática mediante un modelado del caso de estudio, previa búsqueda y análisis de información del mercado empleando también cierta información proporcionada por el cliente.

En primer lugar, tras una minería de datos de matriculaciones en los países de estudio, se desarrolla una estimación de la demanda de coches eléctricos. Esta estimación es necesaria para, junto con la información y objetivos proporcionados por el cliente, realizar el modelado del caso y su posterior resolución. El caso de estudio supone el modelado de un problema de programación Lineal, que resuelve ante un conjunto de fábricas y regiones de demanda la mejor opción de configuración para el cliente, a fin de conocer el mínimo coste posible con el que suministrar la demanda esperada para los próximos cuatro años. Para ello, se consideran las diferentes fábricas de las que dispone o tiene al alcance comprar el cliente, así como los costes fijos y variables asociados.

Mediante el lenguaje de programación Python, y haciendo uso del paquete de optimización lineal PuLP de código abierto y el de estadística Statsmodels, se resuelve el modelo que, una vez descrito en términos matemáticos, es implementado en este lenguaje. De esta forma, se emplea la computación para resolver el problema, obteniendo una solución óptima para el cliente que le permita estimar el coste mínimo total de la red para los cuatro próximos años. Se proporcionan los resultados de qué fábricas comprar o emplear en caso de que estén disponibles, así como qué cantidades se envían desde cada fábrica a cada región de demanda, en cada año analizado.

Palabras clave: Optimización matemática, Series temporales, Cadena de Suministro, Diseño de redes, Programación Lineal.

ABSTRACT

This work solves a fundamental business decision for an electric vehicle manufacturer, who seeks to optimize the Design of its Network in the Supply Chain. That for, mathematical optimization is used through a modeling of the case study, after searching and analyzing market information, also using information provided by the client.

In the first place, after a data mining of registrations in the studied countries, an estimation of the demand for electric cars is developed. This estimate is necessary, together with the information and objectives provided by the client, to carry out the modeling of the case and its subsequent resolution. The case study involves the modeling of a linear programming problem, which solves the best configuration option for the customer before a set of factories and demand regions, in order to know the minimum possible cost with which to supply the expected demand for the next four years. Thus, the different factories that the customer has or is able to buy are considered, as well as the associated fixed and variable costs.

Using the Python programming language, and making use of the open source PuLP linear optimization package and the Statsmodels statistics package, the model is solved which, once described in mathematical terms, is implemented in this language. This way, computing is used to solve the problem, obtaining an optimal solution for the client that allows them to estimate the minimum total cost of the supply for the next four years. The results of which factories to buy or employ if available, are provided, as well as which quantities are shipped from each factory to each demand region, in each year analyzed.

Keywords: Mathematical Optimization, Time Series, Supply Chain, Network Design, Linear Programming

RESUM

Aquest treball resol una decisió de negoci fonamental per a un fabricant de vehicles elèctrics, que busca optimitzar el Disseny de la seua Xarxa en la Cadena de Subministrament. Per a això, s'empren l'optimització matemàtica per mitjà d'un modelatge del cas d'estudi, prèvia la recerca i l'anàlisi d'informació del mercat emprant també una certa informació proporcionada pel client.

En primer lloc, després d'una mineria de dades de matriculacions en els països d'estudi, es desenrotlla una estimació de la demanda de cotxes elèctrics. Esta estimació és necessària per a, junt amb la informació i objectius proporcionats pel client, realitzar el modelatge del cas i la seua posterior resolució. El cas d'estudi suposa el modelatge d'un problema de programació Lineal, que resol davant d'un conjunt de fàbriques i regions de demanda la millor opció de configuració per al client, a fi de conèixer el mínim cost possible amb què subministrar la demanda esperada per als pròxims quatre anys. Per a això, es consideren les diferents fàbriques de què disposa o té a l'abast comprar el client, així com els costos fixos i variables associats.

Per mitjà del llenguatge de programació Python, i fent ús del paquet d'optimització lineal PuLP de codi obert i el d'estadística Statsmodels, es resol el model que, una vegada descrit en termes matemàtics, és implementat en este llenguatge. D'esta manera, s'empra la computació per a resoldre el problema, obtenint una solució òptima per al client que li permeta estimar el cost mínim total de la xarxa per als quatre pròxims anys. Es proporcionen els resultats de quines fàbriques comprar o emprar en el cas que estiguen disponibles, així com quines quantitats s'envien des de cada fàbrica a cada regió de demanda, en cada any analitzat.

Paraules clau: Optimització matemàtica, Sèries temporals, Cadena de Subministrament, Disseny de xarxes, Programació Lineal

ÍNDICE

Resumen	2
Abstract	3
Resum	4
Índice	5
1. INTRODUCCIÓN	7
2. JUSTIFICACIÓN Y OBJETIVOS	13
3. MARCO TEÓRICO	13
3.1 Diseño De Redes En Las Cadenas De Suministro	13
3.2 Optimización Matemática.....	16
3.2.1 Modelado matemático en problemas de optimización.....	17
3.2.2 Optimización mediante entornos de programación.....	19
3.3 Series Temporales Y Predicciones.....	20
3.1 Métodos para predecir series temporales	22
3.2 Predicciones en entornos de programación.....	27
4 CASO DE ESTUDIO	28
4.1 Estimación De La Demanda:.....	35
4.2 Optimización Lineal: Modelado.....	45
4.2.1 Variables de decisión	45
4.2.2 Parámetros de coste	46
4.2.3 Parámetros de demanda y capacidad.....	47
4.2.4 Función objetivo y restricciones	47
5 ANÁLISIS DE LOS RESULTADOS	49
5.1 Demanda Anualizada	49
5.2 Resolución Del Modelo De Optimización.....	56

6 CONCLUSIONES	67
Bibliografía.....	68
ANEXO A:CÓDIGO DE LA ESTIMACIÓN DE LA DEMANDA.....	72
ANEXO B:CÓDIGO DEL MODELADO DE LA OPTIMIZACIÓN	76
Índice de tablas.....	82
Índice de figuras.....	84

1. INTRODUCCIÓN

El continuo progreso de la globalización ha derivado en que, exponencialmente, las compañías hayan visto en ampliar sus fronteras una gran herramienta para el crecimiento [1]. Esto, sin embargo, les ha obligado a tener que mejorar sus cadenas de suministro, como una herramienta clave para ser competitivas. Variedad en la localización de fábricas y clientes, así como el abaratamiento de los métodos de transporte con la mejora de la logística, han promovido el beneficio de la deslocalización de los diferentes agentes que integran las cadenas de suministro [2].

Así, el objetivo de las cadenas de suministro, que es maximizar el valor total generado -diferencia entre lo que vale el producto final para el cliente y los costos en que la cadena incurre-, resulta cada vez más complejo [3]. Esta complejidad, implica intrínsecamente una gran oportunidad para cualquier compañía, por pequeña que sea, de competir contra cualquier gran empresa, si es capaz de optimizar y construir una buena red. La globalización trae oculta consigo fragilidad y capacidad de mejora, por lo que es clave efectuar decisiones estratégicas de manera correcta para minimizar los riesgos asociados. Mercados emergentes que aún no tienen redes consolidadas de suministro, encuentran grandes oportunidades para elaborar estrategias y construir su porvenir.

De esta manera, mercados como el de la movilidad eléctrica, cuya demanda ha aumentado exponencialmente en los últimos años, asociado a una elevada presión social y una buena respuesta de mercado (ver **Figura 1.1**) [4], encuentran su oportunidad.

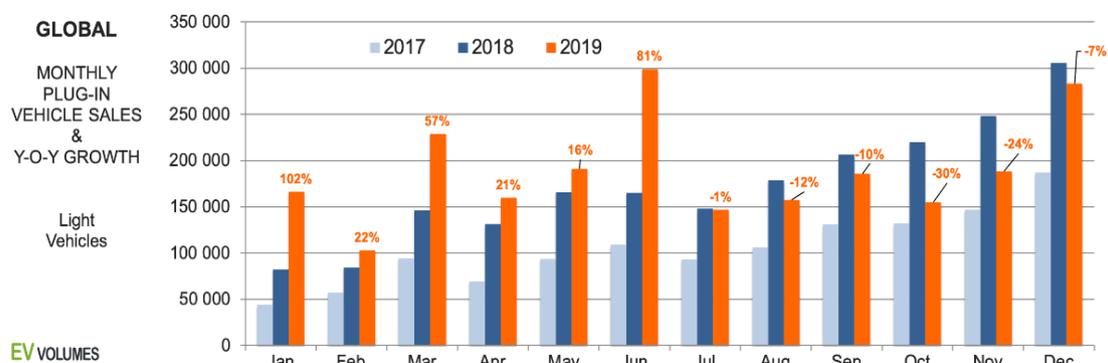


Figura 1.1. [4] Ventas mensuales de vehículos eléctricos durante en los años 2017, 2018 y 2019, según EV Volumes [4].

Automóviles y motocicletas eléctricas son cada vez más comunes en el ecosistema de la movilidad, y se espera que sea mucho mayor y más rápido en los próximos años (ver **Figura 1.2**). Para el caso ilustrativo de España, la movilidad compartida en ciudades como Madrid o Barcelona también ha facilitado su uso, reduciendo la necesidad de inversiones iniciales de los consumidores.



Figura 1.2. Comparación de las ventas de coches eléctricos requeridas anualmente y la cantidad de coches eléctricos en el mercado entre 2018 y la esperada en 2030, para el panorama Europeo¹, según McKinsey&Company [5].

Esta comparativa de las ventas mensuales mostrada en la **Figura 1.1**, puede observarse para España por número de matriculaciones según un estudio del Observatorio del Vehículo Eléctrico y de Movilidad Sostenible de la Universidad Pontificia de Comillas [6] (ver **Figura 1.3**).

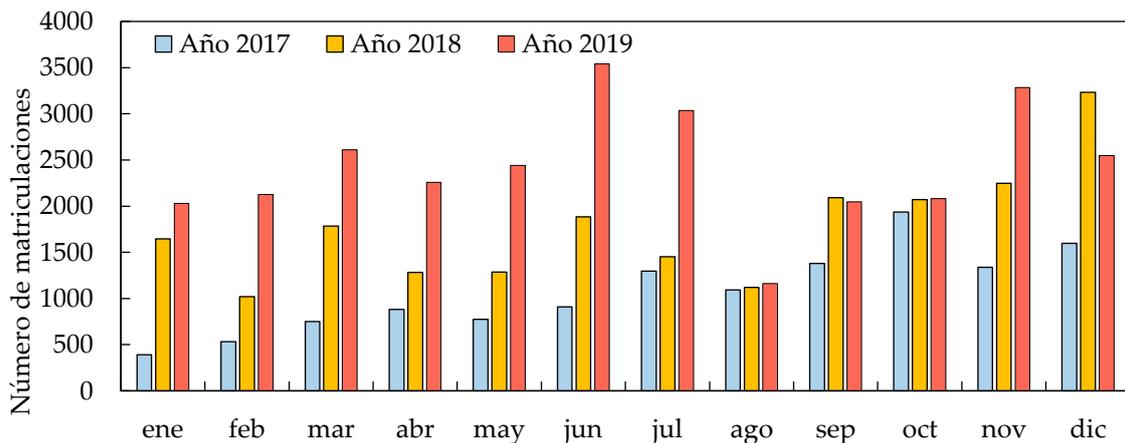


Figura 1.3. Matriculaciones mensuales de coches eléctricos entre 2017 y 2019, según OVEMSComillas [6].

¹ La nota ² de xEV de la figura acota que estos valores en millones de vehículos por año incluyen BEV (Vehículo 100% eléctrico) y PHEV (Coche híbrido enchufable), asumiendo que estos contribuirán predominantemente a reducir las emisiones de CO₂.

En la figura 1.3 se observa el crecimiento sostenido de los vehículos eléctricos en el país, salvando la caída de diciembre de 2019 y un resultado algo inferior del mes de septiembre, así como el ligero aumento de agosto y octubre. Las matriculaciones muestran un claro aumento mensual en años consecutivos. Si ahora se muestra el crecimiento diferenciando entre coches BEV -vehículos 100% eléctrico- y PHEV -coche híbrido enchufable- (ver **Figura 1.4**), así como una distinción del tipo de vehículos, a lo largo de los últimos años (ver **Figura 1.5**), se tiene:

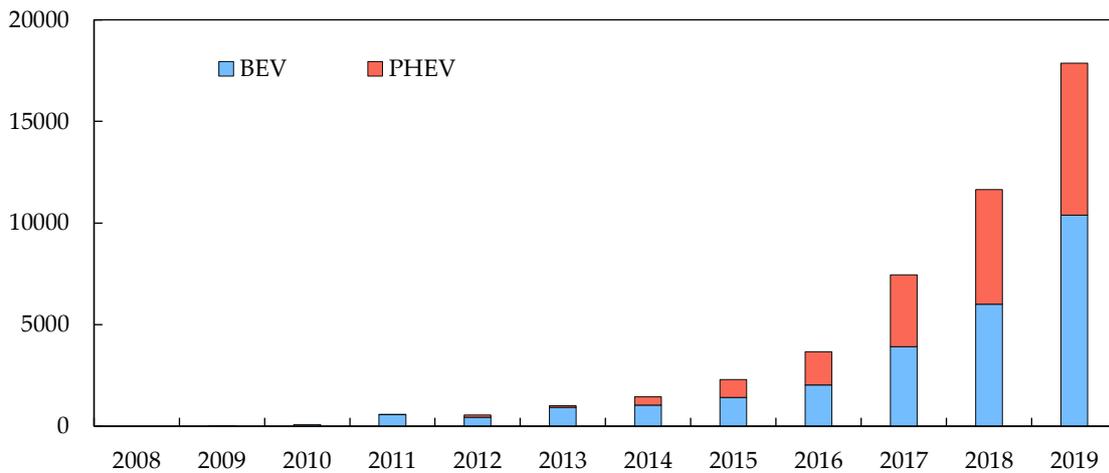


Figura 1.4. Crecimiento de matriculaciones anuales totales en modelos BEV y PHEV en España, entre 2008 y 2019, según OVEMSComillas [6].

Esto también puede analizarse según el tipo de vehículo, entre los años 2011 y 2019 (ver **Figura 1.5**).

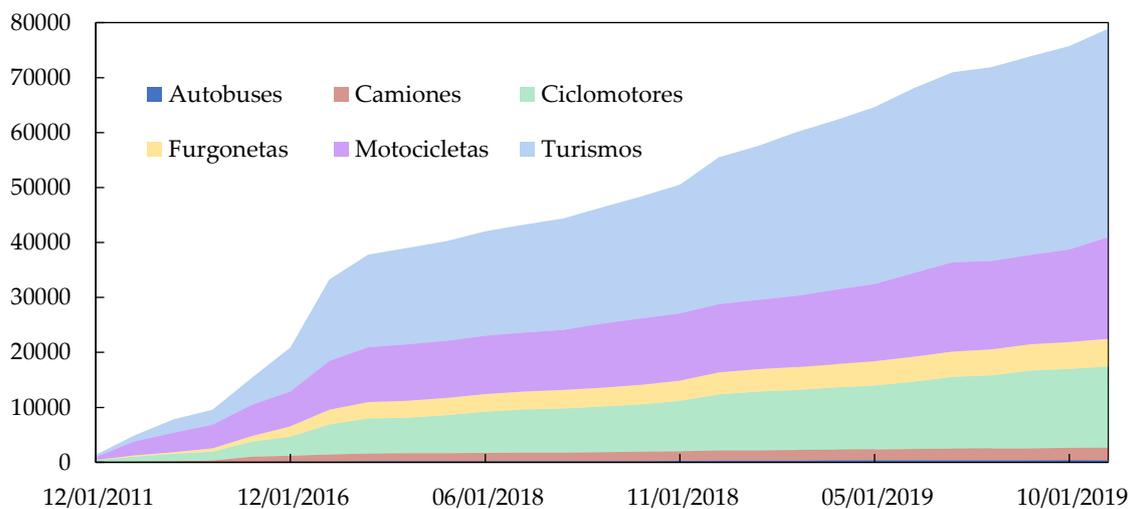


Figura 1.5. Crecimiento de matriculaciones por tipo de vehículo eléctrico entre 2011 y 2019, según OVEMSComillas [6].

Ante esta realidad, el sector automovilístico lleva años mostrando una transición en términos de inversión hacia la movilidad eléctrica, con grandes nuevas compañías alternativas, como Tesla. Así, cada vez es más común encontrar diferentes modelos total o parcialmente eléctricos, con la clara intención de reemplazar en un futuro quién sabe cuánto de cercano los utilitarios a este tipo de sistemas (ver **Figura 1.6**) [4] [7].

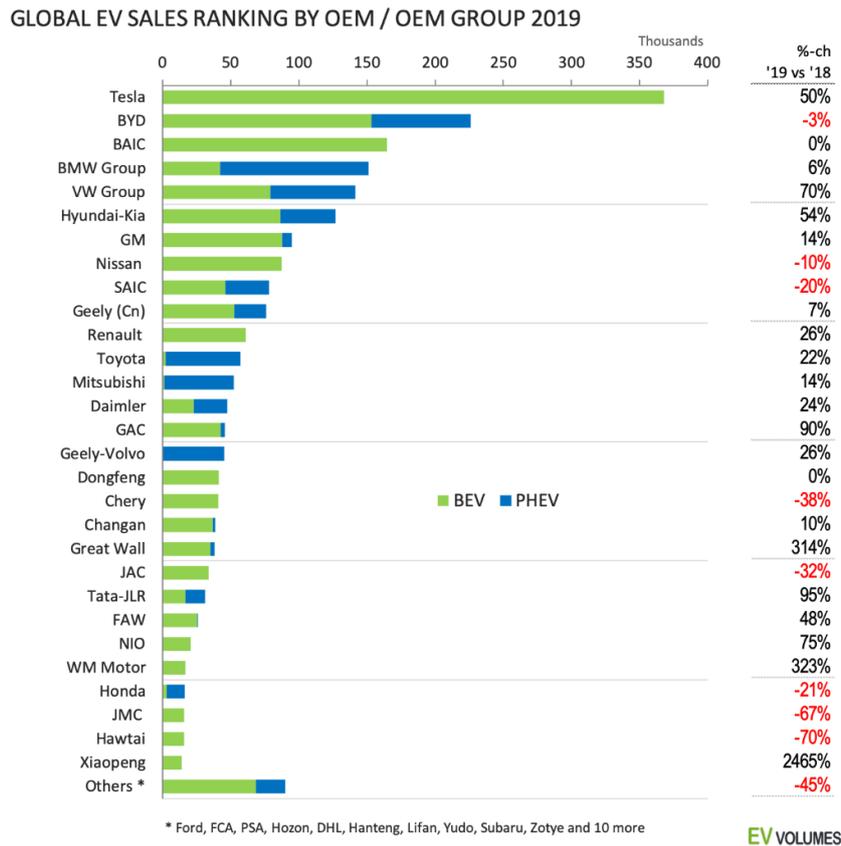


Figura 1.6. Ventas globales de coches eléctricos por marcas en el año 2019, según EV Volumes [4].

Así, resulta sencillo comprender el interés de las compañías fabricantes de este tipo de vehículos de entrar en el mercado europeo, dada la tendencia de crecimiento. Crear las rutas correctas de distribución, ganar la confianza del mercado y posicionarse correctamente en los diferentes países es crucial para que las diferentes compañías puedan ser competitivas en el posible nuevo escenario de demanda.

Este trabajo mezcla la optimización de redes de suministro globales con un caso aplicado a la movilidad eléctrica, mediante un caso de estudio de una compañía

estadounidense que, como estrategia de crecimiento, propone su entrada en Europa. Esta decisión, viene recomendada por un análisis interno por el que entienden que Europa es el gran mercado a dominar, lo que resulta obvio si se observa que, según EV Volumes [4], los continentes con mayor venta de vehículos BEV y PHEV anual son Europa y China, con un crecimiento porcentual de la primera de hasta el 44% en el año 2019, respecto al 2018 (ver **Figura 1.7**). Este gran crecimiento del mercado europeo, comparado al de China, muestra la fase en el que se encuentra. Esto implica que aquellas compañías que tomen gran cuota de mercado, se posicionarán en los primeros lugares de la tabla para los próximos años.

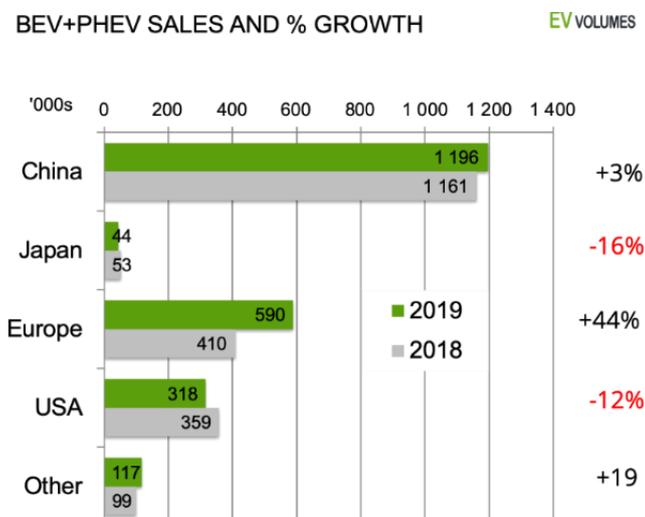


Figura 1.7. Ventas y % crecimiento por países en 2019, según EV Volumes [4].

Para resolver la configuración de la red que permita maximizar los beneficios del cliente -minimizar los costes-, se emplea la Optimización Matemática para el modelado de este problema de Optimización Lineal. Como herramienta de modelado se emplea el lenguaje de programación Python, mediante un paquete de Optimización Lineal escrito en este mismo lenguaje llamado PuLP. Este paquete de optimización es un paquete de software libre que pertenece a COIN|OR (ver **Figura 1.8**) -o por sus siglas en inglés *Computational Infrastructure for Operations Research*-, que es un proyecto para crear “para el software matemático lo que la literatura abierta es para la teoría matemática”.



Figura 1.8. Logotipo de COIN-OR.

Para la solución del problema, que se define con detalle en la sección **CASO DE ESTUDIO**, se realiza previamente una minería de datos de matriculaciones para los países de Europa escogidos. Esto, que se define posteriormente en detalle, se complementa con el crecimiento pasado y esperado de los coches eléctricos en ese número de matriculaciones, así como cuotas de mercado objetivo del cliente. Esta actividad previa constituye una recogida de información importante, a fin de plantear una demanda estimada de coches que se espera vender en el mercado; es decir, la demanda esperada.

La justificación de la demanda esperada, se desarrolla en detalle en el apartado **Estimación De La Demanda**:. Se plantea mediante un análisis previo que emplea tanto datos históricos de matriculaciones, como previsiones y análisis de consultoras estratégicas (ver **Figura 1.2** y **Figura 1.10**)-en este caso, informes de McKinsey & Company [5] [8]-. Los datos históricos de matriculaciones para los países de estudio, son recogidos a partir de la web de ACEA (European Automobile Manufacturers Association, ver **Figura 1.9**). Estos datos históricos proporcionan el número de matriculaciones mes a mes de cada país integrante de Europa -para cada año, dependiendo de si formaba o no parte de la Unión- desde 1990 hasta el año 2019.



Figura 1.9. Logo de la Asociación Europea de Fabricantes de Automóviles.

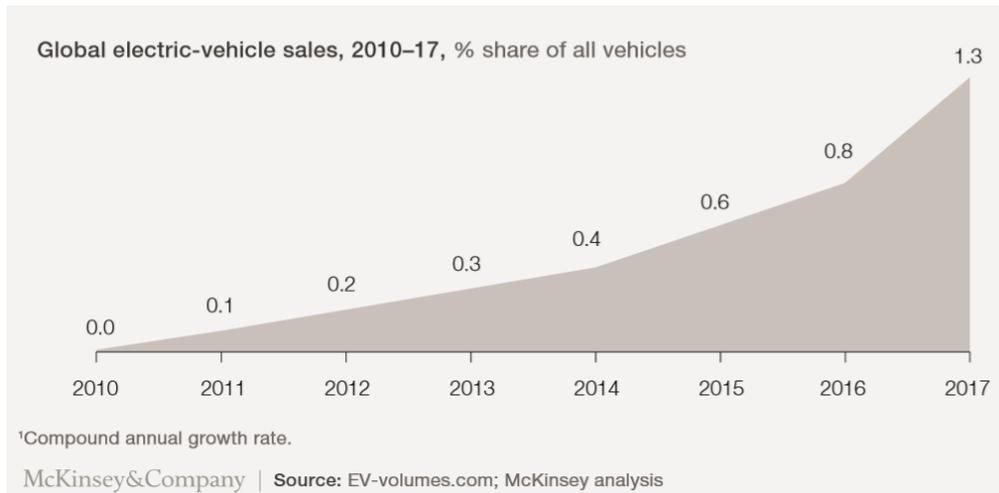


Figura 1.10. Porcentaje del total de coches eléctricos respecto al total de vehículos vendidos en todo el mundo desde 2010 a 2017, según McKinsey&Company [8].

De esta forma, en las siguientes secciones se resuelve el problema del diseño de la Red de la Cadena de Suministro para el cliente ECOCar Inc., aplicando análisis y predicción de series temporales, modelado de Programación Lineal y resolución del mismo, para obtener un coste mínimo del producto con el que obtener un beneficio esperado del 40%, el coste mínimo de la red para la mejor configuración, y cómo debería de distribuirse la misma para cubrir de forma más eficiente la demanda en cada capital.

2. JUSTIFICACIÓN Y OBJETIVOS

En los últimos años, la globalización ha supuesto un importante cambio en las redes de las cadenas de suministro de las compañías, y en cómo estas se organizan para dar servicio a mercados globales.

A su vez, la capacidad que brinda la computación y los lenguajes modernos han abierto puertas a una competencia más directa entre los agentes del mercado, lo que permite a cualquier compañía, por pequeña que sea, a abrirse y posicionarse en todo el mundo. Las estrategias de negocio y la configuración de estas cadenas añade progresivamente mayor complejidad y variables. Decidir qué servicios, a qué clientes y de qué forma es una tarea mucho más compleja, y herramientas como la Programación Lineal ayudan a resolver estos problemas cada vez menos intuitivos.

Este trabajo tiene como objetivo el conectar las herramientas más modernas de optimización matemática con un caso práctico de diseño de Red de Cadena de Suministro. Para ello, se considera el estudio de un sector como el de la movilidad eléctrica, que cuenta con grandes expectativas de crecimiento. Se pretende modelar una situación real supuesta por un cliente para planificar y programar su producción en los próximos años, a fin de cumplir con la estrategia marcada internamente.

Se busca obtener un resultado óptimo que permita contemplar la solución que minimize los costes de fabricación y distribución, considerando con ello todas las variables de decisión.

3. MARCO TEÓRICO

3.1 Diseño De Redes En Las Cadenas De Suministro

El diseño de una red en las cadenas de suministro es una tarea fundamental para un funcionamiento satisfactorio y óptimo en la operativa del suministro de bienes y servicios. Esto es mucho más relevante frente a una operativa internacional, como la propuesta con la globalización [9]. La amplia variedad a escoger en la localización de fábricas, así como en medios de transporte, hacen de esta tarea un punto estratégico fundamental para cualquier compañía, con multitud de variables que resultan difíciles de optimizar.

Las cadenas de suministro están formadas por el conjunto de partes que se involucran en satisfacer una solicitud de servicio para un cliente. Esto puede ser directa o indirectamente, por lo que no únicamente se encuentran englobadas en estas algunas previsible como fabricantes y proveedores, sino hasta servicios como el servicio al cliente [10]. Por red, en cadenas de suministro, se entiende al conjunto de caminos o pasos que sigue un determinado producto desde su fabricación hasta que llega al cliente [11]. El objetivo fundamental en una cadena de suministro es, tal como se comentaba anteriormente en INTRODUCCIÓN, el de maximizar el valor total generado, entendiendo así a la diferencia que existe entre el valor de un determinado producto final para el cliente que lo adquiere y el coste total asociado de fabricarlo y ponerlo a su disposición.

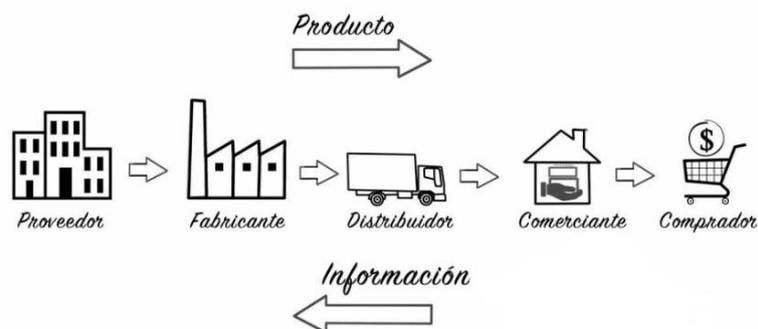


Figura 3.1. Composición y flujos en una cadena de suministro [12].

Available: <https://www.visionindustrial.com.mx/industria/noticias/fraudes-en-la-cadena-de-suministro-cuatro-pasos-basicos-para-prevenirlos>. [Último acceso: 22 noviembre]

El valor total generado está por tanto estrechamente ligado a la rentabilidad de la cadena de suministro. Así, diseñar una red que opere con el menor coste posible, manteniendo la máxima calidad deseada, es fundamental para la rentabilidad de la compañía y poder ser competitivos en precio con el resto de productos o servicios provistos por el mercado [13]. Por lo cual, las decisiones relativas al diseño, la planificación y la operación de una cadena de suministro son claves para el éxito o fracaso de una compañía. Algunas de las decisiones que abordar en el diseño de la red de una cadena de suministro, son [10]:

a. Papel de las instalaciones:

Uno de los aspectos claves a decidir es qué función se realizará en cada una de las instalaciones que posee la compañía, o por las que pasa el producto de la misma. Tiempo requerido en el procesamiento y costes asociados serán fundamentales para poder seleccionar entre las diferentes posibilidades.

b. Ubicación de las instalaciones:

Decidir dónde se ubica cada una de las instalaciones es fundamental, principalmente a largo plazo. Considerar posibles expansiones y dónde operará la compañía puede ser clave para ponderar correctamente las opciones. Una correcta elección permite aumentar capacidad de respuesta manteniendo costes en bajos niveles.

c. Asignación de la capacidad:

Otra variable fundamental, aditiva a las dos anteriores, será decidir qué capacidad tendrá, para la función correspondiente, cada fábrica. Esta decisión tiene un impacto significativo en el desempeño [1]. Estas decisiones son comunmente más flexibles que las anteriores, aunque su asignación es igualmente clave en el desempeño de la cadena de suministro, en tiempo y coste. Como ejemplo, se podría observar una pobre capacidad de respuesta cuando la capacidad asignada es muy pequeña, así como altos costes cuando la demanda a cubrir supera a la capacidad asignada.

d. Asignación del mercado y la oferta:

Por último, otro de los factores clave a decidir en el diseño es el de a qué mercados debe responder cada instalación, así como qué fuentes de suministro alimentarán a cada una. Esta asignación tiene una alta repercusión en el desempeño, puesto que afecta al coste total de producción, inventario y transporte de la cadena para lograr la satisfacción de la demanda del cliente.

Esta decisión, al contrario que las previas, es dinámica. Se debe reconsiderar según la situación del mercado, a fin de optimizar el servicio y los recursos disponibles para satisfacer la demanda.

Para la toma de estas decisiones, siguiendo las recomendaciones de S. Chopra y P. Meindl [10], es también importante considerar algunos factores secundarios que también tienen un gran impacto en el funcionamiento de las instalaciones:

- Tener en cuenta el tiempo de vida de las instalaciones.
- Considerar la importancia de implicaciones culturales.
- No obviar los aspectos de calidad de vida.
- Enfocarse en aranceles e incentivos fiscales en el proceso de ubicación de instalaciones.

Encontrar la solución óptima en términos de coste, cumpliendo los requisitos de entrega, no es una tarea sencilla. Diseñar la red de la cadena de suministro es una tarea estratégica que, como tal, debe considerar el mayor número de parámetros relevantes posible. Para ello, conocer el mercado y prever su demanda resultan de gran utilidad para poder plantear la fabricación de fábricas e infraestructuras que lleva extenso espacio temporal amortizar. El principal objetivo a conseguir en el proceso de ubicar instalaciones y asignar capacidad es el de maximizar la rentabilidad total de la red de la cadena de suministro, proporcionando al mismo tiempo una capacidad de respuesta adecuada para los clientes.

La optimización en el diseño de redes en las cadenas de suministro se emplea para decidir dónde se establecerán las instalaciones así como qué capacidad se le asignará a cada una. De igual manera, permiten asignar la demanda actual a las instalaciones

disponibles e identificar las rutas de transporte del producto. Para poder modelar correctamente este tipo de problemas, es necesario disponer de la información adecuada para tomar una decisión adecuada. Entre esta información, según S. Chopra y P. Meindl [10], se encuentra:

- Ubicación de las fuentes de abastecimiento y de los mercados.
- Posibles ubicaciones de las instalaciones.
- Previsión de la demanda por mercado.
- Costes de instalación, mano de obra y material por ubicación.
- Costes de transporte entre cada par de sitios.
- Costes de inventario por sitio y como una función de la cantidad.
- Precio de venta del producto en diferentes regiones.
- Impuestos y aranceles.
- Tiempo de respuesta deseado y otros factores de servicio.

En vista a contextualizar adecuadamente las operaciones que posteriormente se modelan, resulta fundamental comprender qué es la previsión de demanda, cuáles son los métodos disponibles para estimarla, qué es la optimización matemática, y cómo esta puede aplicarse al diseño de redes de la cadena de suministro.

3.2 Optimización Matemática

Según Daniel N. Wilke y Jan A. Snymany [14], la optimización matemática o investigación operativa es el proceso que combina la formulación y solución de un problema de optimización restringido, de forma matemática. Atendiendo a una definición más precisa, la optimización matemática, o investigación operativa, es el conjunto de técnicas matemáticas de modelización que permite la resolución de problemas de asignación o planificación óptima de recursos escasos, entre muchos otros, contribuyendo en el proceso de toma de decisiones eficiente [15].

Resulta ahora necesario comprender qué se entiende por óptima. Una solución óptima, refiere a que su obtención se ha realizado mediante un proceso de optimización, que es el objetivo final de la investigación operativa [16]. Optimizar es el proceso de búsqueda de la mejor forma para realizar una actividad concreta. En términos

matemáticos, esto es encontrar el máximo o mínimo de una función concreta (siempre que sea posible), en un determinado dominio. Así, la investigación operativa emplea modelos matemáticos para resolver problemas complejos de optimización de recursos [17].

Los objetivos de la optimización pueden ser diversos, principalmente, puede encontrarse los siguientes:

- a. Reducir costes
- b. Maximizar los ingresos
- c. Minimizar tiempos de respuesta.

3.2.1 Modelado matemático en problemas de optimización

Para llevar a cabo el modelado matemático de un problema de optimización matemática, es necesario seguir un conjunto de etapas (ver Tabla 1) [18], atendiendo a tres elementos básicos y fundamentales, como son [18] [19]:

1) Variables de decisión:

Las variables son el elemento del problema a resolver. Obtener una solución para un modelo de optimización matemático significa obtener el valor de estas variables independientes para el que se maximiza o minimiza la función objetivo, según el caso. El primer paso para modelar un problema de optimización es escoger adecuadamente estas variables, que tendrán un alto impacto en la función objetivo.

Las variables independientes se representan mediante vectores columna de \mathbb{R}^n , o vectores fila:

$$\text{Vectores columna} \rightarrow x = \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix} \quad \text{Vectores fila} \rightarrow x^T = (x_1, \dots, x_n)$$

Las variables pueden ser fundamentalmente binarias, enteras o continuas, dependiendo de los valores que puedan tomar en la solución.

2) Función objetivo:

Esta es la función matemática que mide cómo de efectiva es la selección de las variables de decisión en el sistema a optimizar. La solución óptima, resultante de la optimización, será aquella que resulte en el mejor valor de esta función, según sea el tipo de optimización [16].

3) Restricciones:

Son las ecuaciones e inecuaciones -igualdad y desigualdad- que restringen los posibles valores que las variables de decisión pueden tomar. Sirven para delimitar las soluciones y adaptar los resultados posibles a la realidad del modelo de estudio. Su definición es fundamental.

Siguiendo la definición anterior, y mediante la definición de Silvestre G. Paredes [19], pueden distinguirse los siguientes dos tipos de restricciones:

a. Restricciones de igualdad:

$$h(x) = h(x_1, \dots, x_n) = 0$$

donde $h : A \subseteq \mathbb{R}^n \rightarrow \mathbb{R}$ es una función real de variables reales definida sobre un conjunto A de números reales.

b. Restricciones de desigualdad:

$$g(x) = g(x_1, \dots, x_n) \leq 0$$

donde $g : A \subseteq \mathbb{R}^n \rightarrow \mathbb{R}$ es una función real de variables reales definida sobre un conjunto A de números reales.

Tabla 1. Etapas que seguir en la realización de un proyecto de Investigación Operativa [20].

Etapas de un Proyecto de Investigación Operativa
1. Formulación del problema
2. Construcción de un modelo matemático que lo represente
3. Obtención de una solución
4. Verificación del modelo y de la solución
5. Puesta en práctica y mantenimiento de la solución

Para el diseño de redes en las cadenas de distribución, la técnica más empleada es la de la Programación Entera. Este tipo de técnicas buscan la optimización de una función objetivo lineal, sometida a un conjunto determinado de restricciones expresadas mediante un sistema de inecuaciones lineales [21]. El objetivo es encontrar la mejor solución, que no necesariamente tiene que ser única [18]. Este modelo es el más antiguo y desarrollado en programación matemática, comenzando en 1947 por George B. Dantzig con el método simplex para resolver este tipo de problemas [22].

3.2.2 Optimización mediante entornos de programación

Para resolver problemas de optimización matemática, es necesario realizar complejas operaciones que, de hacer manualmente, llevarían bastante tiempo. Gracias a los avances de la computación, se puede hacer uso de la misma para abordar este tipo de problemas, y solucionarlos igualmente de forma mucho más dinámica y eficaz. Los lenguajes de programación ayudan a plantear problemas como estos para resolverlos con el poder computacional existente. En este caso, se empleará el lenguaje de programación Python, por la sencillez del mismo y por la amplia cantidad de paquetes con herramientas para el modelado de este tipo de problemas.

De entre los paquetes disponibles en Python para la resolución de problemas de optimización matemática, se puede encontrar, principalmente:

1) PuLP

Esta es una librería que proporciona un entorno para modelar y resolver problemas de optimización de programación lineal. Únicamente permite resolver problemas de optimización lineal.

2) Scipy.optimize:

Este paquete es el módulo de optimización de la librería SciPy. Aquí se pueden encontrar diferentes rutinas para la resolución de problemas de optimización no lineales. En este caso, no es útil dado que no puede resolver problemas de optimización lineal, y tampoco maneja datos de tipo entero.



Figura 3.2. Logo de la librería SciPy [23].

3) CVXopt

Esta es una librería desarrollada por Martin Andersen, Joachim Dahl y Lieven Vandenberghe [24], cuya utilidad es la de proporcionar un entorno de optimización matemática para problemas de optimización convexa -minimización-. Esta librería permite resolver problemas de programación lineal.

4) Pyomo

Esta última es otra librería ampliamente conocida, que proporciona un lenguaje para modelar problemas de optimización en Python. Requiere de solvers externos para resolver los problemas modelados. Esta librería fue desarrollada por investigadores del Centro de Investigación de Computación de los Laboratorios Nacionales de Sandia, bajo proyecto COIN-OR.



Figura 3.3. Logotipo de la librería Pyomo [25].

En este trabajo se ha decidido emplear PuLP, dada la sencillez de su lenguaje, así como el gran ajuste que su contorno proporciona a este tipo de problemas.

3.3 Series Temporales Y Predicciones

Una serie temporal es un conjunto o colección de valores de una determinada variable, recogidos de forma secuencial durante el tiempo, normalmente de forma equiespaciada. Para los casos equiespaciados, la periodicidad puede ser anual, semestral,

trimestral, mensual, etc., dependiendo siempre del caso y los objetivos. Una de las mayores utilidades de las series temporales es su análisis, mediante técnicas estadísticas, que permite comprender y modelizar cómo es el comportamiento de un determinado fenómeno en el tiempo, y con ello realizar previsiones de los valores futuros [26, 27, 28].

Para el caso de la predicción de la demanda, las series temporales emplean la demanda histórica para conocer la futura, suponiendo que los datos de demanda pasada son buenos indicadores de la demanda futura. Realizar las previsiones de demanda a partir de los históricos de demanda pasada resulta el procedimiento adecuado en aquellos casos en que el patrón de demanda básica no presenta variaciones grandes entre años consecutivos [10].

Para realizar un análisis de una serie temporal, independientemente de la variable de estudio, se realiza una descomposición de la misma en varias componentes básicas, para así entender su comportamiento. Las componentes habitualmente consideradas son:

- Tendencia:

Es un cambio a largo plazo que se produce en relación al nivel medio, o el cambio a largo plazo de la media. Las series temporales pueden presentar tendencias aditivas, en caso de que presenten crecimiento o decrecimiento lineal, o multiplicativas en caso de que sea exponencial.

- Efecto Estacional:

Variación periódica y predecible de la serie, para un determinado periodo de tiempo, comúnmente anual. De igual forma que para la tendencia, la estacionalidad también puede presentar un carácter aditivo o multiplicativo .

- Componente Aleatoria:

Es la parte impredecible que resulta tras retirar la tendencia y estacionalidad de la serie; es decir, la parte de la predicción que se desvía de la parte sistemática -entendiendo sistemática la suma de la tendencia y la estacionalidad-.

3.1 Métodos para predecir series temporales

La predicción es una tarea estadística habitual en los negocios, que ayuda a recopilar información útil para la toma de decisiones a largo plazo. Predecir es, a partir de la información disponible, estimar lo más preciso posible cómo será el futuro. Para ello, se consideran datos históricos, así como cualquier conocimiento que se tenga sobre eventos futuros que podrían impactar a las predicciones [10, 29, 30, 31]. Existe una gran variedad de métodos para predecir series temporales, y escoger uno u otro depende siempre del tipo de serie temporal analizada. Identificar si los datos presentan tendencia y/o estacionalidad es fundamental para saber si un conjunto puede predecirse a partir de un determinado método (ver **Figura 3.4**) [27].

	1 No efecto estacional	2 Estacionalidad Aditiva	3 Estacionalidad multiplicativa
A No efecto tendencia			
B Tendencia aditiva			
C Tendencia multiplicativa			

Figura 3.4. Recopilación de las conductas de datos según la clasificación de Pegel [32].

➤ **Media móvil**

El método de la media móvil solo sirve para estimar o predecir series temporales sin tendencia ni estacionalidad. Su aplicación debe centrarse en el medio plazo, y consiste en asumir que los valores futuros dependen de la media de los n valores pasados. Cuando se tiene un modelo vivo; es decir, en los casos en que se van actualizando los datos y reajustando el modelo, la media móvil avanza en el conjunto en los datos reajustando el valor de las predicciones futuras. En caso de que los datos históricos no se actualicen, sus predicciones siempre resultan con el mismo valor. A mayor valor de n , mayor influencia de los datos pasados [33].

$$x_{i+1} = \frac{s_i + s_{i-1} + \dots + s_{i-n+1}}{n}$$

Donde,

x_{i+1} : valor de la media móvil en el periodo $i + 1$

s_i : valor histórico de la variable de estudio en el periodo i .

n : número de datos pasados que se consideran en la media.

➤ **Alisado exponencial**

Para los métodos de alisado exponencial, es muy importante la clasificación de Pegel (ver **Figura 3.4**) para escoger entre los tres tipos. Se puede distinguir entre el alisado simple, doble o triple, y escoger uno u otro se determina principalmente por si hay tendencia y/o estacionalidad. Estos métodos resultan una metodología sencilla de calcular, además de evitar los problemas de las medias móviles, y están basados en la suavización o promedio de los valores pasados de una serie de forma exponencialmente decreciente [29, 33].

- **Alisado exponencial simple:**

El alisado exponencial simple es únicamente aplicable a conjunto de datos sin tendencia ni estacionalidad. Las predicciones se realizan a partir de una suma ponderada de las observaciones pasadas, a partir de un factor α de alisado. Este parámetro determina cómo de rápido la influencia de los datos pasados disminuye con el tiempo, y toma valores de entre 0 y 1. Cuando el valor es elevado para este parámetro, el modelo presta atención principalmente a las observaciones pasadas más recientes, mientras que los valores más pequeños significan que se tiene más en cuenta la historia al hacer una predicción. De esta forma, la expresión matemática que lo describe es:

$$s_i = \alpha x_i + (1 - \alpha)s_{i-1}$$

Donde,

- x_i : valor actual a tiempo i .

- s_i : el nivel a tiempo i .

- α : factor de alisado para el nivel.

- **Alisado exponencial doble o Holt**

El alisado exponencial doble es una extensión del simple, que añadiendo un nuevo parámetro β considera también la tendencia en las series temporales univariantes. Además de este parámetro, cuyo valor se encuentra en el rango $0 < \beta < 1$, el método considera también el factor de alisamiento presentado en el alisado exponencial simple, α , y permite predecir series temporales con tendencias de tipo aditivo y multiplicativo -dependiendo de si la tendencia es lineal o exponencial (ver **Figura 3.4**)-. Este método se conoce también como el método de Holt, en honor a su desarrollador Charles Holt [35].

Las ecuaciones fundamentales del método son:

$$s_i = \alpha x_i + (1 - \alpha)(s_{i-1} + t_{i-1})$$

$$t_i = \beta(s_i - s_{i-1}) + (1 - \beta)t_{i-1}$$

$$f_{i+1} = s_i + t_i$$

Donde:

- f_{i+1} : predicción a tiempo $i + 1$.
- t_i : componente de tendencia en el tiempo i .
- β : factor de alisado para la tendencia.

- **Alisado exponencial triple o Holt-Winters**

El alisado exponencial triple es una extensión del método de alisado exponencial doble, pero considerando ahora también la estacionalidad, para series temporales de una sola variable. También conocido como Holt-Winters, en honor a la combinación del anterior de Holt [35] y a Peter Winters [36], además de los parámetros α y β del modelo de alisado exponencial doble, se considera un nuevo parámetro denominado γ . Mediante este, se incluye la influencia de la estacionalidad, y al igual que los anteriores, su valor se encuentra entre $0 < \gamma < 1$.

Al igual que para la tendencia, la estacionalidad puede ser tanto aditiva como multiplicativa, como se refleja en la clasificación de Pagel (ver **Figura 3.4**). Es el modelo de suavizado exponencial más avanzado, y según los datos puede también desarrollar comportamiento de doble o simple. Además de estos tres parámetros del modelo, es importante incluir para modelar correctamente la estacionalidad el número de pasos del periodo. De esta forma, para un caso en que los datos de la serie temporal son mensuales, y el periodo de estacionalidad se repite para cada año, el número de pasos o periodos sería 12 [31].

1) Estacionalidad aditiva:

En el caso de que la estacionalidad del modelo sea aditiva, las expresiones matemáticas que describen el mismo son:

$$s_i = \alpha(x_i - p_{i-k}) + (1 - \alpha)(s_{i-1} + t_{i-1})$$

$$t_i = \beta(s_i - s_{i-1}) + (1 - \beta)t_{i-1}$$

$$p_i = \gamma(x_i - s_i) + (1 - \gamma)p_{i-k}$$

$$f_i = s_i + t_{i-1} + p_{i-k}$$

Donde:

- p_i : componente de estacionalidad a tiempo i .
- γ : factor de alisado para la estacionalidad.
- k : periodo para la serie temporal.

2) Estacionalidad multiplicativa:

En el caso de que la estacionalidad sea multiplicativa, las expresiones que describen el método son:

$$s_i = \alpha \frac{x_i}{p_{i-k}} + (1 - \alpha)(s_{i-1} + t_{i-1})$$

$$t_i = \beta(s_i - s_{i-1}) + (1 - \beta)t_{i-1}$$

$$p_i = \gamma \frac{x_i}{s_i} + (1 - \gamma)p_{i-k}$$

$$f_{i+1} = (s_i + t_i)p_{i+1}$$

Donde:

- t_i : componente de tendencia en el tiempo i.
- p_i : componente de estacionalidad a tiempo i.

➤ ARIMA

Además de los métodos anteriores, existen otros métodos mucho más generalistas y también bastante empleados que son los denominados modelos ARIMA. Junto con el suavizado exponencial, son los dos más empleados para la estimación o predicción de series temporales, proporcionando enfoques complementarios. Al contrario que los modelos de suavizado exponencial, cuyo fundamento está en una descripción de la tendencia y la estacionalidad en los datos, los modelos ARIMA buscan describir autocorrelaciones en los datos históricos [29, 36].

Denominados ARIMA, acrónimo en inglés de “AutoRegressive Integrated Moving Average”, también se engloba dentro de los modelos ARIMA al que considera la estacionalidad, mediante el acrónimo SARIMA, que no es más que ARIMA con “Seasonal” o estacionalidad. Estos modelos se fundamentan por 3 parámetros a definir, para el caso del ARIMA, que son [30, 37]:

- p: orden de la parte autorregresiva de la serie estacionaria.
- d: número de diferencias que tomar para que una serie que no era estacionaria lo sea.
- q: orden de la media móvil de la serie estacionaria.

Y 3 parámetros más además de los anteriores para el caso de los modelos SARIMA; es decir, en el caso de que se incluya estacionalidad en la serie, que dependen de la estacionalidad. Estos parámetros son P, Q y D, que son similares a los de no estacionalidad pero considerando el retroceso de los periodos con estacionalidad.

$$ARIMA \rightarrow \underbrace{(p, d, q)}_{\text{Parte no estacional del modelo}} \underbrace{(P, D, Q)_m}_{\text{Parte estacional del modelo}}$$

Donde:

- m: longitud del ciclo estacional.

Este método no se ha utilizado en este estudio.

3.2 Predicciones en entornos de programación

La predicción o estimación de las series temporales involucra una gran cantidad de datos históricos, especialmente en algunos métodos. Así, las herramientas de computación y los paquetes con métodos ya implementados facilitan mucho las tareas de estudio, al igual que para la Optimización Lineal, facilitando los cálculos. Para el caso de las series temporales y su predicción, destaca la librería statsmodels [38], que incluye todos los métodos comentados anteriormente (ver **Figura 3.5**).

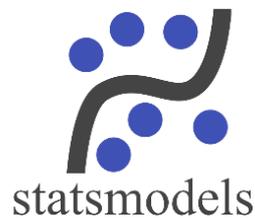


Figura 3.5. Logotipo de la librería de Python Statsmodels.

Para este trabajo, se hará uso de esta librería para realizar los cálculos, así como un apoyo de matplotlib [39] para la representación gráfica de las tendencias históricas y de predicción (ver **Figura 3.6**). Esto facilita comprobar que los resultados son los esperados y analizar mejor las series.



Figura 3.6. Logotipo de la librería de Python Matplotlib.

4 CASO DE ESTUDIO

Una vez se han abordado los fundamentos esenciales para el desarrollo de este trabajo, se procede a describir en detalle el caso de estudio. Para ello, se cuenta con la información proporcionada por el cliente, así como el objetivo y consideraciones del mismo. Para el caso de estudio, una compañía fabricante de vehículos eléctricos denominada ECOCar Inc. (ver **Figura 4.1**) requiere conocer el mínimo coste unitario que tendrían sus coches eléctricos para su entrada en Europa. Actualmente, la compañía opera en Estados Unidos y China, y plantea el mercado europeo en su estrategia a 5 años como una buena oportunidad de crecimiento.



Figura 4.1. Logotipo de la compañía ECOCar Inc.

Para este fin, la compañía quiere conocer cómo, ante las posibilidades de que dispone, debería diseñar su red de cadena de suministro para poder minimizar los costes de sus vehículos, a fin de ser más competitivos. Para ello, la compañía solicita que se optimice considerando la información proporcionada su cadena de suministro, bajo ciertas suposiciones en el estudio. Entre estas suposiciones, se considera:

- El número de matriculaciones anuales puede considerarse igual a la demanda de coches nuevos anualmente.
- La compañía cubrirá una cuota de mercado para cada país, región y año según los porcentajes de la **Tabla 3** y **Tabla 4**, de vehículos eléctricos.
- Considerar las matriculaciones totales con independencia a los modelos, y los vehículos eléctricos como un porcentaje de los mismos justificadamente esperado por fuentes de estudio estratégico.

Así, este estudio representa una información preliminar para el cliente que permite conocer el coste mínimo al que podrían producir los vehículos, sin considerar imprevistos, inventarios y fluctuaciones entre modelos. ECOCar Inc. afirma que los países a los que pretende entrar en los próximos 5 años son España, Italia, Francia, Alemania y Holanda. Asegura que será capaz de hacerse progresivamente con una cuota en algunos países europeos, y que pondrá un mayor interés y detalle en España por ser de estos el menos avanzado en términos de penetración de coches eléctricos en el total. Esta decisión les permitirá tomar el liderazgo en el mercado y afianzar las redes y confianza de la marca.

Para ello, la información relativa a costes y localizaciones es proporcionada por la compañía, facilitando el proceso de optimización y limitando la responsabilidad del estudio al correcto modelado. Entre la información proporcionada, se encuentra la capacidad anual, el coste unitario, el coste fijo anual así como el coste inicial de construcción o compra, según el caso, para las posibles instalaciones (ver **Tabla 2**). Entre estas posibles instalaciones, se encuentran tanto las que ya tienen disponibles, como las que se podría construir o comprar.

De igual manera, la compañía proporciona la cuota de mercado que busca ocupar en cada país según bloques anualizados, para los próximos 4 años (ver **Tabla 3** y **Tabla 4**), considerando 2020 como inoperativo. En esta, se comprueba la estrategia de expansión que propone la compañía, con mayor detalle inicial en puntos concretos de España, y planteando progresivamente expansión en puntos centrales de otros países de Europa. Entre esos países, se encuentra Alemania, Francia, Italia y Holanda. Para ellos, no se especifican ciudades, sino que la compañía proporciona las cantidades totales anuales de demanda para esas ciudades. Esto se debe a que pretenden realizar la entrega centralizada a las capitales de cada una de estas ciudades, para después dejar a los distribuidores mayoristas de cada ciudad la redistribución y venta de los vehículos.

En cuanto al coste asociado de transporte de los productos a las regiones de demanda, para cada fábrica, se encuentran resumidos por coste anual de 1000 unidades enviadas en la **Tabla 4**. Este coste engloba, en cada caso, el coste combinado del envío

de 1000 unidades desde una fábrica a una región de demanda, considerando en él las diferentes combinaciones de transporte englobadas -transporte marítimo, aéreo, ferroviario o rodado-. Esta información ya viene proporcionada por el proveedor de la logística de la compañía, tras evaluar los costes para cada caso.

Así, este análisis requiere de una estimación previa de demanda total en cada país, a fin de conocer la demanda que espera cubrir ECOCar Inc. Por tanto, se requiere de un simplificado estudio previo para obtener esta información, mientras el resto es proporcionada por el cliente. Así, se busca obtener la mejor combinación a un coste minimizado para la consideración del nuevo mercado en la cadena de suministro del cliente. A partir de este trabajo, se proporciona a ECOCar Inc. qué fábricas de las ya construidas y con capacidad disponible debería emplear, si debería construir alguna más de las posibles, y en cualquier caso, qué coste fijo tendría para la compañía este nuevo mercado, en la situación óptima. Así, conocer qué precios serían necesarios para poder obtener la rentabilidad esperada en su inversión. A continuación, se muestran las diferentes tablas proporcionadas por la compañía para realizar el análisis:

Tabla 2. Costes y capacidad para cada una de las posibles localizaciones, así como la información relativa a su situación actual.

Localización de la fábrica	Coste unitario	Capacidad anual (miles ud)	Coste fijo anual	Coste de compra/construcción	Situación actual
Marruecos	200 €	8	12000 €	-	A
Houston	460 €	20	30000 €	300000 €	B
México	280 €	12	10900 €	200000 €	B
Argentina	400 €	6	10000 €	100000 €	C
España	500 €	10	21000 €	250000 €	B
China	93 €	20	13000 €	90000 €	C
Mumbai	240 €	12	19000 €	-	A
Taiwan	185 €	10	15000 €	80000 €	C
Alemania	590 €	8	25000 €	270000 €	B

Situación actual

- A: propiedad de la compañía.
- B: requiere compra de fábrica y maquinaria de fabricación.
- C: requiere compra de fábrica, pero se encuentra equipada.

Tabla 3. Objetivo anual de cuota de mercado en Europa, durante los cuatro años de estrategia planteada por ECOCar Inc.

Demanda anual	España	Alemania	Francia	Italia	Holanda
Año 1 (% mercado)	25%	0%	5%	5%	0%
Año 2 (% mercado)	30%	5%	10%	10%	5%
Año 3 (% mercado)	35%	10%	20%	25%	15%
Año 4 (% mercado)	40%	15%	25%	30%	20%

Tabla 4. Detalle de la distribución según ciudades para la cuota total de España planeada por ECOCar Inc.

Demanda anual	Madrid	Barcelona	Sevilla	Valencia	Bilbao
Distribución % del total	55%	25%	5%	10%	5%

Tabla 5. Coste de las diferentes entregas desde cada fábrica a cada región de demanda. Costes por cada mil unidades de envío.

Localización de la fábrica	Madrid	Barcelona	Sevilla	Valencia	Bilbao	Alemania	Francia	Italia	Holanda
Marruecos	20000 €	22500 €	15000 €	17000 €	30000 €	40000 €	30000 €	20000 €	42000 €
Houston	40000 €	42000 €	35000 €	39000 €	37000 €	50000 €	48000 €	60000 €	80000 €
México	41200 €	45000 €	38000 €	42000 €	40000 €	54200 €	50000 €	61000 €	82000 €
Argentina	50000 €	50000 €	42000 €	49000 €	50000 €	60000 €	55000 €	66000 €	88000 €
España	2000 €	4000 €	4500 €	3000 €	4000 €	15000 €	10000 €	12000 €	20000 €
China	60000 €	48000 €	70000 €	55000 €	80000 €	55000 €	60000 €	50000 €	65000 €
Mumbai	50000 €	43000 €	59000€	41000 €	61250 €	50000 €	45000 €	35000 €	38000 €
Taiwan	48000 €	42000 €	52000 €	40000 €	54000 €	59000 €	52000 €	38000 €	55000 €
Alemania	16500 €	13500 €	25000 €	18000 €	15000 €	2000 €	4000 €	5000 €	5000 €

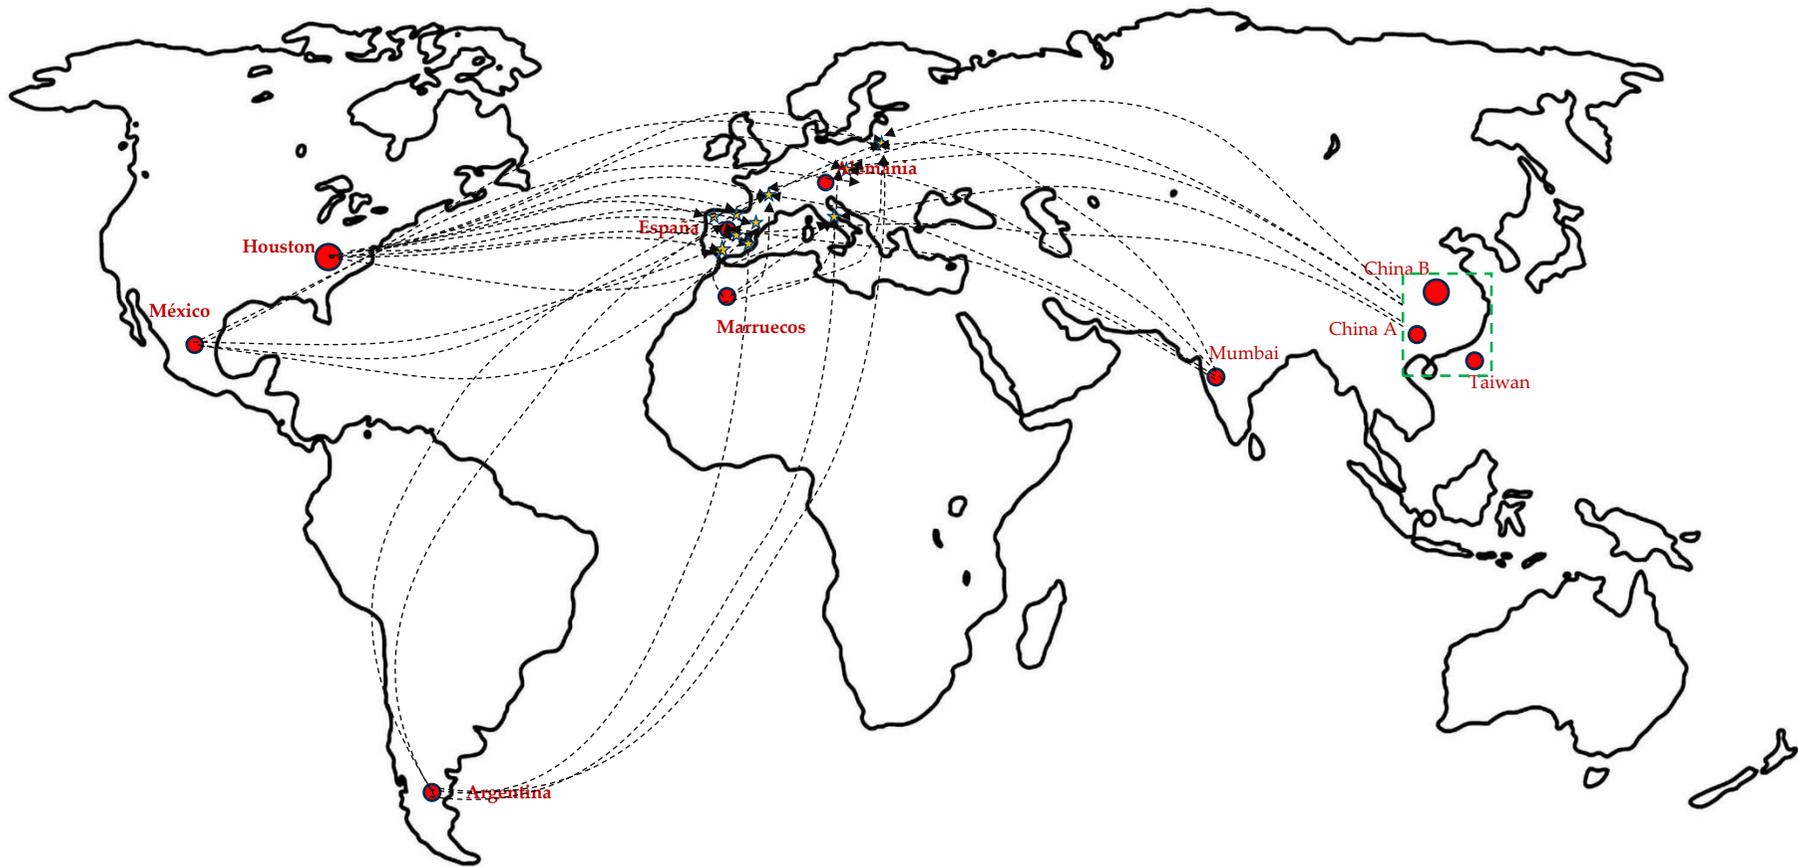


Figura 4.2. Localizaciones posibles para las fábricas por el cliente -marcadas con círculos- y regiones de demanda -señaladas mediante estrellas-. Movimientos posibles, de forma simplificada, representados con flechas discontinuas. Las flechas no son representativas de las rutas empleadas, en ningún caso. Fuente : Elaboración propia.

4.1 Estimación De La Demanda:

Para la estimación de la demanda de vehículos eléctricos, a fin de conocer los datos de demanda del modelo de Programación Lineal, es necesario realizar previamente un estudio con los datos de matriculaciones. De esta forma, y siguiendo las consideraciones de ECOCar Inc. de tomar los datos de matriculaciones como demanda total esperada anual, se requiere conocer para cada país del modelo los datos de matriculación previamente.

Para esto, se ha hecho uso de los datos históricos de matriculación extrayéndolos de la web de ACEA (European Automobile Manufacturers Association, ver **Figura 1.9**) [32]. En esta web, se recogen los datos de matriculación por países de Europa desde el año 1990 hasta el 2019, considerando cada año solo aquellos que por entonces formaran parte de la Unión Europea. De igual forma, también se recoge en la misma los datos de matriculación de coches eléctricos para cada uno de esos países. Así, tomando solo los países objeto de estudio, que son España, Francia, Alemania, Italia y Holanda, se representa gráficamente la serie temporal para cada uno de esos países, según la **Figura 4.3**.

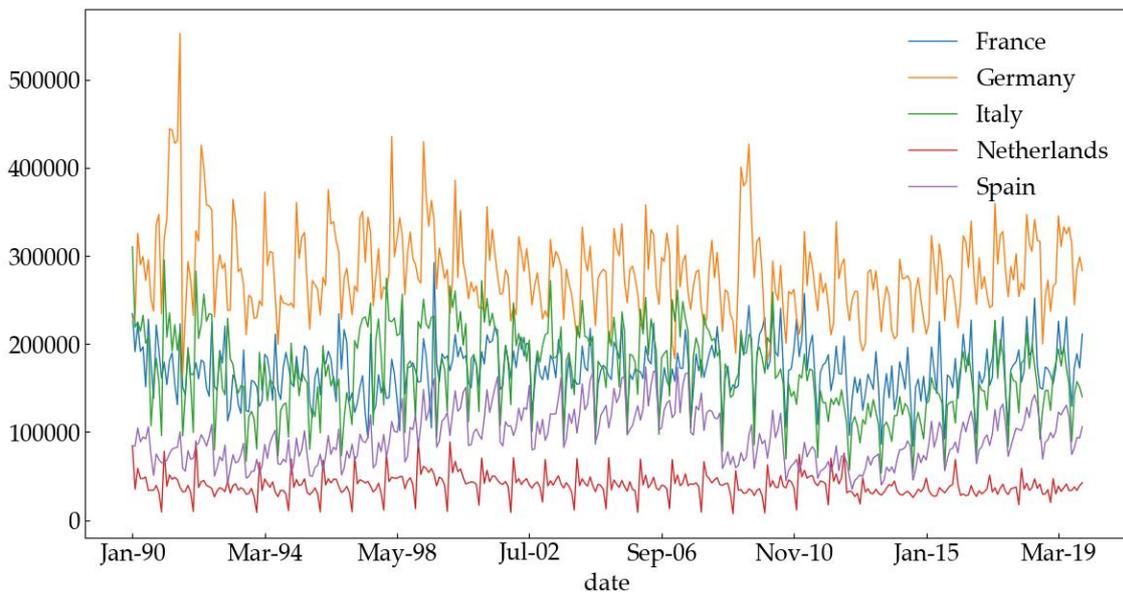


Figura 4.3. Datos mensuales de matriculación históricos para cada uno de los cinco países de estudio desde el año 1990 hasta el 2019. Fuente ACEA [32].

La observación previa de los datos es fundamental, pues para realizar una estimación de las matriculaciones, o tomando las consideraciones de ECOCar Inc., la demanda de automóviles, es fundamental conocer cómo se comporta el conjunto de datos. Atendiendo a la **Figura 4.3**, se observa una evidente estacionalidad en las series; sin embargo, la tendencia varía en algunos países según el conjunto de años observado. En el caso de Alemania, se observa un ruido mayor en algunos periodos históricos, como en el año 1990 y en el 2009. De igual forma, para Holanda se observa un cambio en la estacionalidad posteriormente al año 2011. Tras el año 2010, se observa un comportamiento más estable del histórico de datos con referencia a las fechas últimas de la serie histórica.

De esta forma, parece que una muestra con menor ruido será la de los últimos años. Dada la rapidez en el cambio del sector, se tomará únicamente los últimos datos históricos para las estimaciones. Si se atiende a periodos entre 5 y 10 años atrás, se puede comprobar cómo países como España e Italia muestran tendencias más pronunciadas en el número de matriculaciones. Esto podría justificar la decisión estratégica de entrada en España por el cliente. A fin de comprobar mejor esa estacionalidad y observar la tendencia mes a mes equivalente en los datos, en la **Figura 4.4**, **Figura 4.5**, **Figura 4.6**, **Figura 4.7** y **Figura 4.8** se estudian los últimos 5 años para cada país.

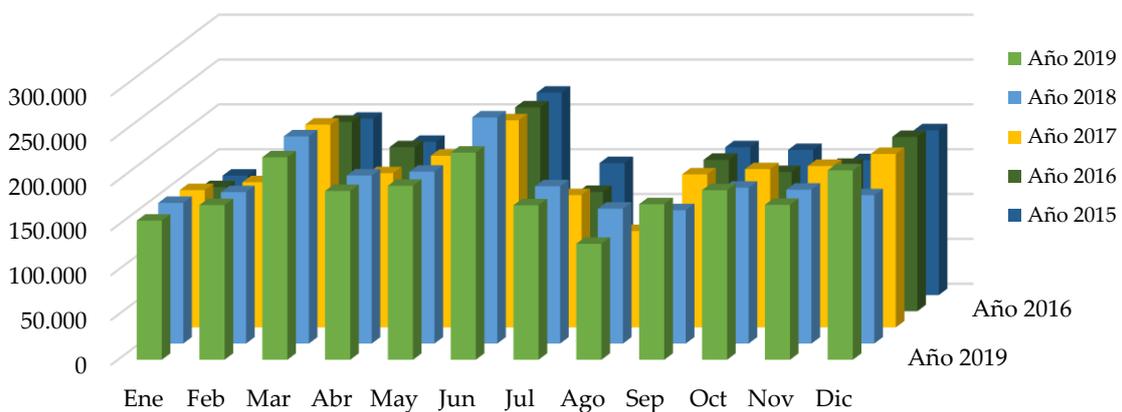


Figura 4.4. Datos de matriculación de automóviles en Francia desde el año 2015 al año 2019. Fuente ACEA [32].

Para el caso de Francia, se observa una estacionalidad clara en los datos, con picos en junio, marzo y diciembre de cada año. Los valores más bajos son siempre en agosto, y no se observa una tendencia clara creciente; sin embargo, atendiendo a la **Figura 4.9** sí que se puede observar una ligera tendencia del acumulado anual creciente. Un comportamiento similar sucede para el conjunto de datos desde el año 2015 de Alemania (ver **Figura 4.5**).

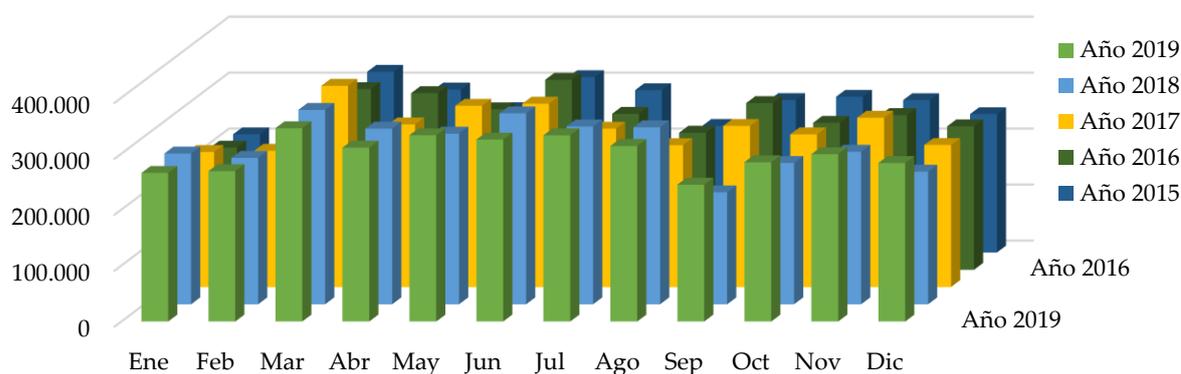


Figura 4.5. Datos de matriculación de automóviles en Alemania desde el año 2015 al año 2019. Fuente ACEA [32].

Aunque los datos también presentan estacionalidad, la variación para este caso es algo menor entre los meses. Destaca para los datos de Alemania que, mientras los mínimos en Francia se obtienen en agosto, para todos los años, en el conjunto de Alemania se desplaza hasta el mes de septiembre, al menos para los dos últimos años. Junio es también uno de los mejores meses para Alemania, aunque no presenta la singularidad observada en los datos de Francia. Para el caso de Alemania, la tendencia creciente del acumulado anual es más clara, y con mayor inclinación que la del caso de Francia (ver **Figura 4.9**).

Si se analizan ahora los datos de Italia (ver **Figura 4.6**), se tiene un conjunto con estacionalidad y tendencia similar entre los acumulados de los últimos cinco años a la observada para Alemania (ver **Figura 4.9**). En este caso, agosto es claramente el mes de menor número de matriculación, con una elevada diferencia respecto al resto de datos. Mayo es, junto a marzo, el mes con mayor número de matriculaciones.

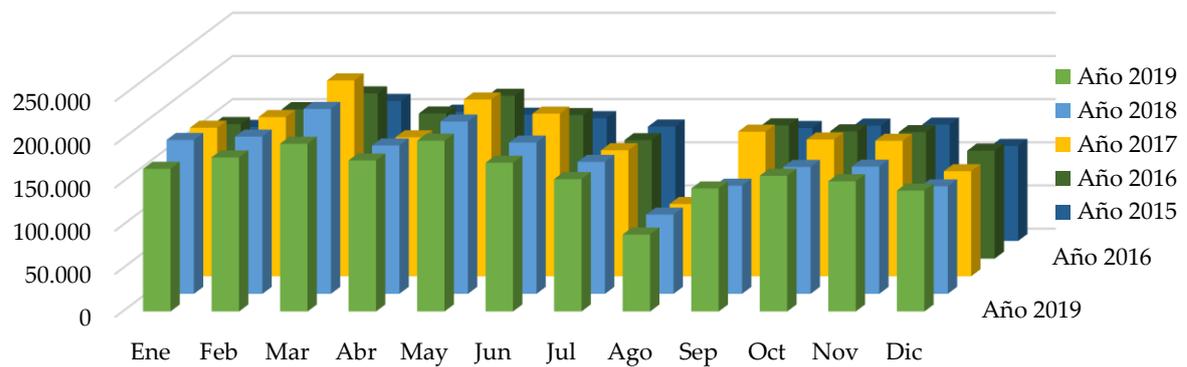


Figura 4.6. Datos de matriculación de automóviles en Italia desde el año 2015 al año 2019. Fuente ACEA [32].

Para el caso de Holanda, se observa un comportamiento en los datos de matriculaciones de los últimos 5 años algo diferente a los países anteriores (ver **Figura 4.7** y **Figura 4.9**). En este caso, existe un alto nivel de singularidades. Para diciembre de 2015, existe un número de matriculaciones muy alto, así como para el mes de enero de 2018, aunque de menor magnitud. Diciembre de 2018 y 2017 presentan valores muy bajos de matriculaciones, pese a que el resto de meses tienen niveles semejantes a los de años anteriores. Para el caso de las matriculaciones acumuladas anuales, la tendencia es ligeramente descendiente, al contrario del resto de países analizados. Los datos atípicos pueden, a priori, que estén relacionados con algún hecho concreto.

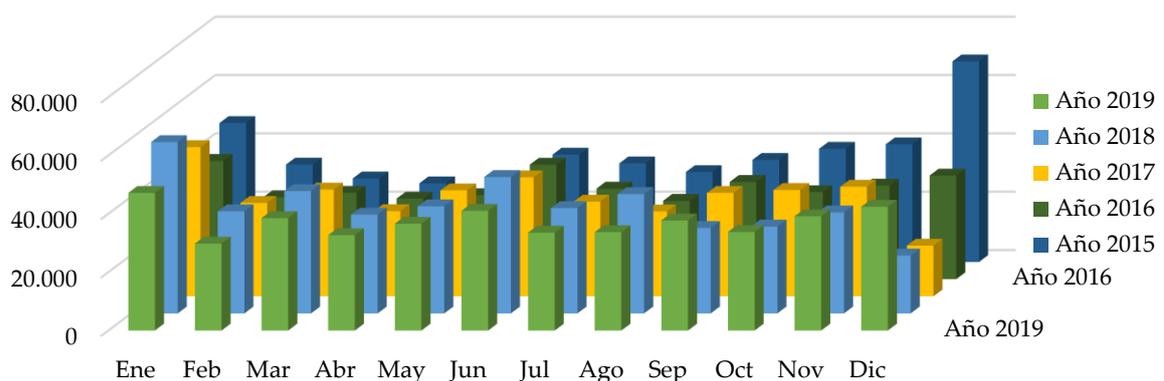


Figura 4.7. Datos de matriculación de automóviles en Holanda desde el año 2015 al año 2019. Fuente ACEA [32].

Por último, el conjunto de datos para España (ver **Figura 4.8**) presenta de nuevo una estacionalidad clara, con estabilidad en los valores y sin atípicos, salvo en el mes de

agosto de 2018. Para España, tanto agosto como septiembre son los meses con menor número de matriculaciones, y junio es el mes con mayor. Desde marzo hasta julio son los meses con mejores valores de matriculaciones. En cuanto al número de acumulados anuales (ver **Figura 4.9**), para los últimos 5 años también se observa una tendencia creciente, al igual que para casi todos los países -con excepción de Holanda-.

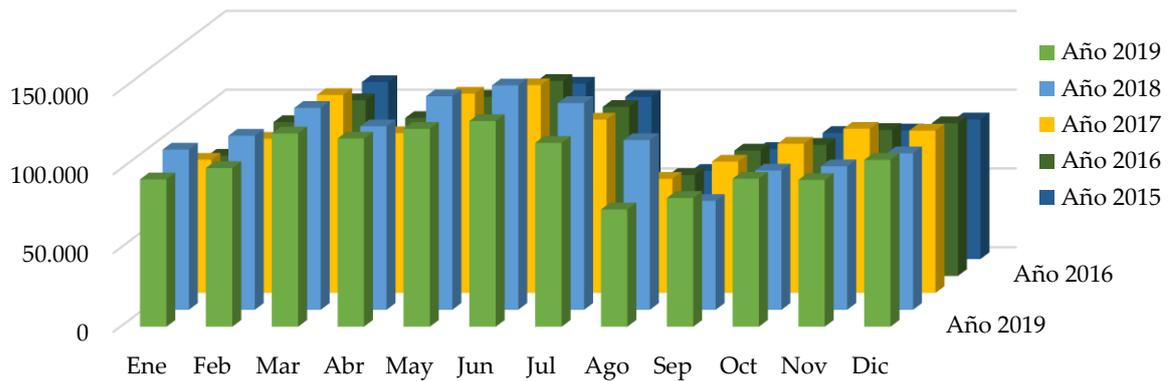


Figura 4.8. Datos de matriculación de automóviles en España desde el año 2015 al año 2019. Fuente ACEA.

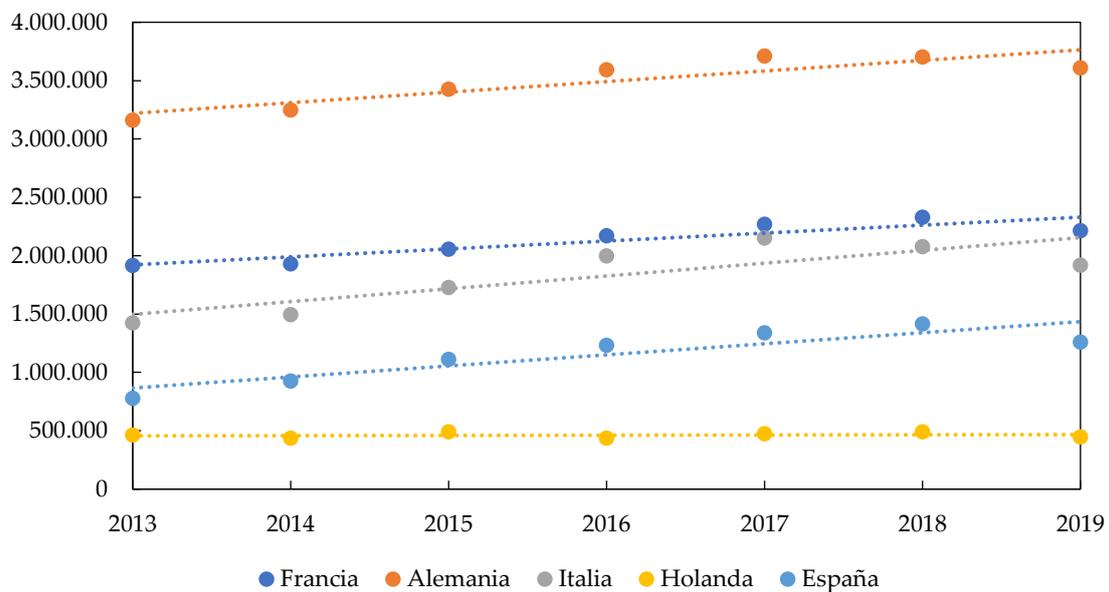


Figura 4.9. Matriculaciones anuales acumuladas para cada país desde el año 2013 al 2020.

Al igual que para el total de matriculaciones de turismos, también se han extraído de acumulados de coches eléctricos de ACEA [32], para los últimos años 5 años (ver **Figura 4.12**). En estos datos se puede apreciar cómo, principalmente para Holanda y Alemania, los crecimientos son mucho más rápidos de lo que se obtenía para las matriculaciones totales. Para el caso de Holanda, esto es especialmente significativo, pues al tiempo que las matriculaciones totales incluso descienden, su distribución crece rápidamente entorno a las vehículos eléctricos.

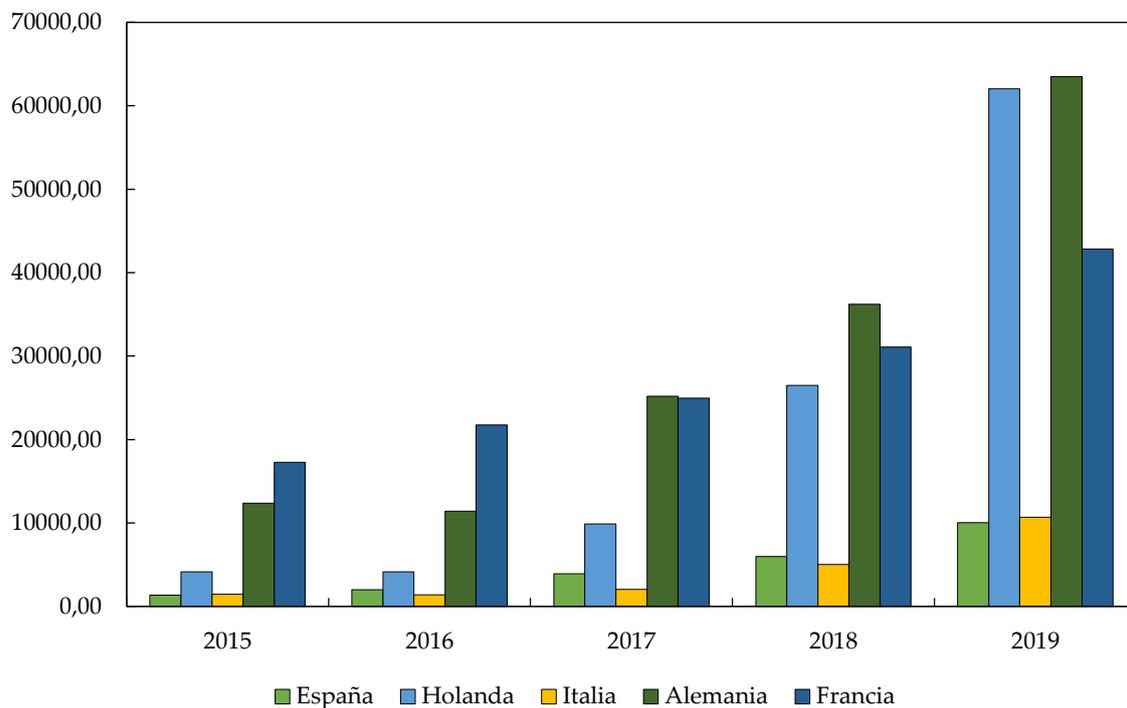


Figura 4.12. Datos de matriculaciones anuales de coches eléctricos para los diferentes países del estudio. Fuente ACEA [32].

Si se calcula el porcentaje de estos coches eléctricos respecto del total, entonces se obtiene el porcentaje de penetración de vehículos eléctricos para cada país, respecto de las matriculaciones anuales (ver Figura 4.13). Esta representación muestra un crecimiento constante para Francia, Alemania, Italia y España; sin embargo, un gran crecimiento para las matriculaciones en Holanda.

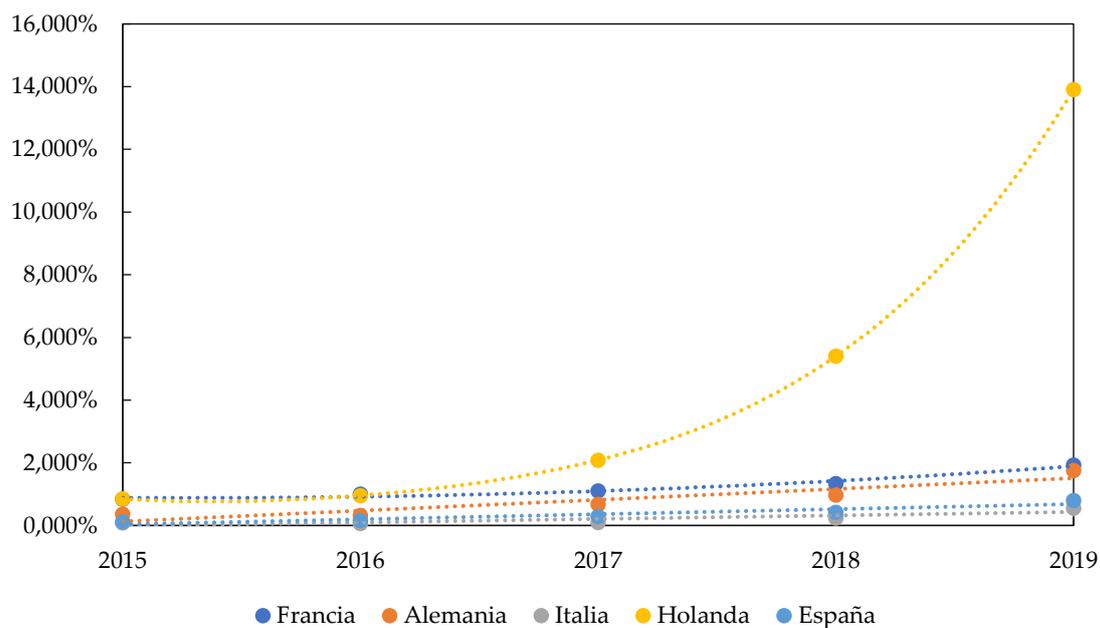


Figura 4.13. Porcentaje de matriculaciones de coches eléctricos respecto del total para los últimos 5 años, según ACEA [32].

Estos datos, junto con las estimaciones presentadas por McKinsey&Company [5, 8] permiten establecer un contexto sobre el que se realizarán estimaciones de crecimiento para los próximos cuatro años (ver **Figura 4.14**). Dado que es un sector en pleno crecimiento, en este caso el análisis de series temporales no ofrece tanta información como el de las matriculaciones. La tendencia estimada a partir de datos históricos de matriculaciones es altamente probable que se cumpla, mientras que cuánto porcentaje de estas es de vehículos eléctricos, tiene mayor incertidumbre.

De esta forma, para el caso de Holanda, considerando la gran variación del último año, se propone llegar hasta una cuota del 23% para el año 2024, a partir de un ajuste lineal (ver **Figura 4.14**). Esto es, considerando que el último año de la estimación tiene ese valor, ajustar considerando los previos mediante un ajuste lineal. Aunque esto no concuerda con la tendencia observada en los últimos años, supone una propuesta más conservadora para evitar que estimaciones excesivas situaran en Holanda una mayor demanda de la requerida, aumentando costes unitarios por inventario y depreciación.

Para el resto de países, se han considerado tendencias polinómicas de grado 2, con suposiciones al año 2024 de 4.3% para Francia, 4.8% para Alemania, 1.8% para Italia y 2.3% para España (ver **Figura 4.14**). De esta forma, el resto de años se completa a partir de las tendencias de este ajuste polinómico. Estas previsiones, aunque se asemejan bastante a una tendencia lineal para todos los países, suponen más del 200% de crecimiento respecto del año 2019. Para Italia, estas estimaciones superan incluso el 300% de crecimiento respecto al año 2019.

Tabla 6. Previsiones para los próximos cuatro años -con inicio en la serie en 2021- de coches eléctricos respecto del total de matriculaciones.

Año	Francia	Alemania	Italia	Holanda	España
2021	2.533%	2.542%	0.872%	13.992%	1.174%
2022	3.132%	3.323%	1.188%	16.869%	1.549%
2023	3.730%	4.105%	1.504%	19.926%	1.924%
2024	4.329%	4.887%	1.819%	22.983%	2.300%

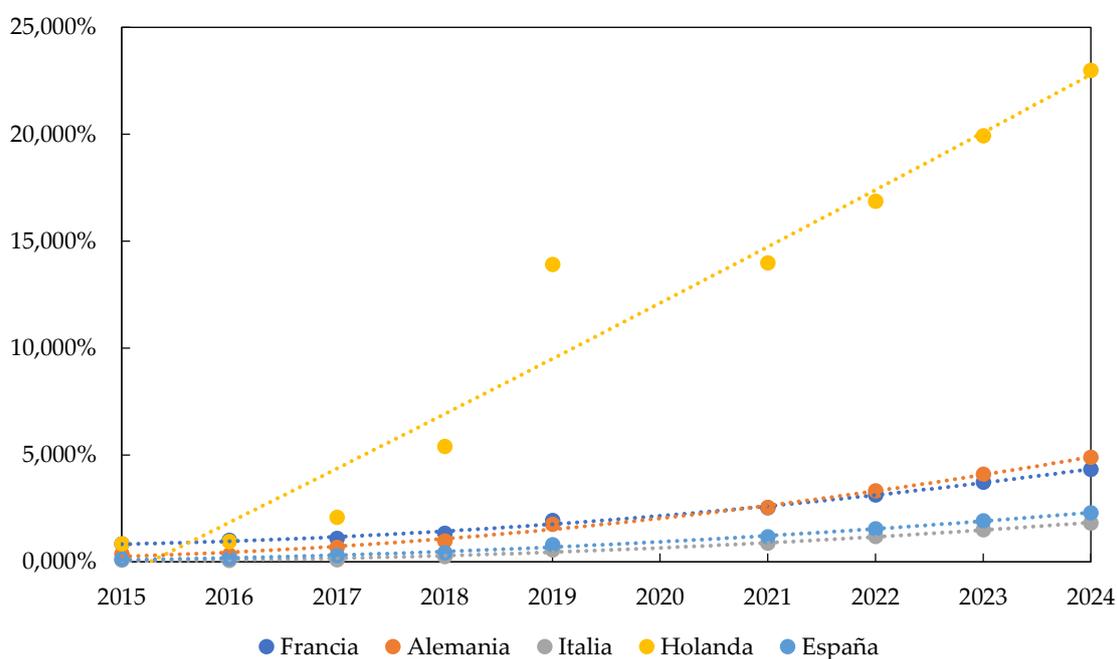


Figura 4.14. Previsiones para los próximos 4 años -con inicio de la serie en 2021- del porcentaje respecto del total de coches eléctricos en el total de las matriculaciones.

Así, a partir de todas las consideraciones anteriores y siguiendo la teoría desarrollada en el apartado 3.3, la estimación para cada uno de los países se realiza mediante el uso combinado de Python y el paquete Statsmodels. Se ha empleado el modelo de Holt-Winters para estimar en base a los datos históricos las matriculaciones futuras. El análisis combinatorio con el porcentaje de coches eléctricos considerado cada año, y el cálculo del acumulado posterior, se realiza en detalle en el apartado 4.1. El código implementado para realizar estas estimaciones se recoge en ANEXO A:. Para la parametrización realizada del modelo, se ha hecho uso de la guía de la **Figura 3.4** para entender cada combinación de tendencias y estacionalidad.

4.2 Optimización Lineal: Modelado

Para poder desarrollar el modelo bajo el lenguaje de programación Python, usando el paquete de optimización PuLP, como se anticipaba previamente en la **INTRODUCCIÓN**, es necesario un modelado en términos matemáticos previo. De esta forma, identificar los conjuntos fundamentales de todo problema de optimización (ver **Modelado matemático en problemas de optimización**) es clave para modelar posteriormente el problema de forma correcta.

Se procede a identificar estos 3 grupos que componen un problema de optimización matemática, así como los parámetros influyentes en el modelado. Respecto a estos tres grupos fundamentales, son:

- Variables de decisión
- Función objetivo
- Restricciones

4.2.1 Variables de decisión

Para este problema, se tendrán variables de tipo entero y también binarias. Se definen a continuación:

➤ **Enteras**

x_{lji} = cantidad de vehículos enviadas en el año l desde la fábrica i a la región de demanda j .

Donde,

- $l = \{1, \dots, r\}$, siendo $r = 4$
- $j = \{1, \dots, m\}$, siendo $m = 9$
- $i = \{1, \dots, n\}$, siendo $n = 9$

Refiere a la cantidad que, para un determinado año l , una determinada fábrica i envía a una determinada región de demanda j . Esta es la variable, que denominaremos x_{lji} , pues implica intrínsecamente de dónde viene y hacia dónde va cada vehículo en cada año. Se puede ver los valores de las fábricas (i) y los destinos (j) en la **Tabla 5**.

➤ **Binarias**

k_{li} = Toma valor '1', si en el año l una determinada fábrica i se emplea en la distribución. Y '0' en caso contrario.

Esta variable justifica si se compra, construye o emplea una fábrica en un determinado año o no. Como restricción, se deberá tener en cuenta que una vez se emplea una fábrica se sigue usando. Esto viene a justificar que, una vez construida una fábrica, esta ya forma parte de la red. Por tanto, toda aquella fábrica empleada al principio del proceso seguirá dando apoyo. Es decir, si una fábrica se abre en el año '1', seguirá abierta en los años $(l+1)$ y posteriores.

Tras definir las variables del modelo, es necesario conocer los parámetros de coste que intervienen en la función objetivo, que vendrán definidos por las tablas anteriores **Tabla 2** y **Tabla 4**, así como otros parámetros fundamentales para las restricciones, como son demanda y capacidad, que vienen recopilados en la **Tabla 2** y **Tabla 3**.

4.2.2 Parámetros de coste

En este punto, se definen los diferentes parámetros de coste que formarán parte de la función objetivo, que son:

- Coste unitario de fabricar el producto:

p_i = coste de producción unitaria en la fábrica i .

Donde,

$$i = \{1, \dots, n\}$$

- Coste de compra o construcción de una determinada fábrica

m_i = coste de compra o adquisición de la fábrica i .

Donde,

$$i = \{1, \dots, n\}$$

- Costes fijos de una determinada fábrica:

s_i = coste fijo anual por tener la fábrica i operativa.

Donde,

$$i = \{1, \dots, n\}$$

- Coste logístico:

l_{ij} = coste de enviar 1000 ud desde la fábrica i hasta la región de demanda j .

Donde,

$$i = \{1, \dots, n\}$$

$$j = \{1, \dots, m\}$$

4.2.3 Parámetros de demanda y capacidad

- Capacidad anual de cada fábrica:

C_{ii} = capacidad anual en miles de unidades de la fábrica i en el año l

- Demanda:

D_{lj} = demanda en miles de unidades de la región j en el año l.

4.2.4 Función objetivo y restricciones

Una vez conocidas las variables y parámetros de coste que conglomeran el caso de estudio, se procede a definir la función objetivo, sujeta a determinadas restricciones. Para ello, se considera que el coste total asociado a la cadena de suministro es el coste de producir los vehículos eléctricos y enviarlos -cuyo coste unitario dependerá de dónde se ha fabricado, y el coste de envío a dónde se manda ese vehículo- mas el coste asociado a construir o comprar, en el caso de que deba hacerse, mas los costes fijos de cada fábrica.

Para esta función objetivo, hay un conjunto de restricciones a cumplir que determinarán los resultados obtenidos. Estas crean las condiciones de contorno para una solución acotada. En primer lugar, se debe cumplir la condición de no negatividad; esto es, ninguna fábrica puede producir menos de cero vehículos. Por otro lado, las variables binarias solo pueden valer uno o cero. En cuanto a la demanda, la cantidad de envíos que se hacen en un determinado año a una determinada región de demanda debe cubrir al menos a la demanda de ese año. Por último, ninguna fábrica puede producir más anualmente de la capacidad de la misma.

Así, en términos matemáticos este modelo resulta:

$$\min z = \sum_{i=1}^n \sum_{l=1}^r \sum_{j=1}^m (1000 \cdot p_i + l_{ij}) \cdot x_{lij} + \sum_{l=1}^r \sum_{i=1}^n m_i \cdot k_{li} + \sum_{l=1}^r \sum_{i=1}^n s_i \cdot k_{li} \quad (1)$$

sujeto a:

$$x_{ijl} \geq 0 \rightarrow \text{No negatividad}$$

$$x \in \mathbb{Z}^+ \rightarrow \text{Unidades enteras}$$

$$k_{li} = \{0, 1\} \rightarrow \text{Binarias a 1 y 0}$$

$$\sum_{j=1}^m x_{lij} \leq c_{li} \cdot k_{li} \quad ; \quad i = \{1, \dots, n\} ; l = \{1, \dots, r\} \quad (2)$$

$$\sum_{i=1}^n x_{lij} \geq d_{lj} \quad ; \quad l = \{1, \dots, r\} ; j = \{1, \dots, m\} \quad (3)$$

$$k_{li} \leq k_{(l+1)i} \quad ; \quad l = \{1, \dots, r-1\} \quad ; \quad i = \{1, \dots, n\} \quad (4)$$

(1) → Tenemos la función objetivo, que minimizamos los costes que esta formada por tres sumandos. Minimizar el coste de producción y transporte, el coste de construir, más el coste fijo de trabajar con la fábrica.

(2) → Con las restricciones del grupo 2, nos aseguramos de que cada fabrica en cada año, no se envían más unidades de la capacidad marcada, en el caso de estar activa.

(3) → Con las restricciones del grupo 3, nos aseguramos de que se cubre la demanda en cada destino para cada año

(4) → Con las restricciones del grupo 4, nos asegura que, si una fábrica esta abierta en el año "x", estará abierta en los años posteriores.

Conociendo el modelo anteriormente expuesto, así como los datos proporcionados por el cliente recogidos en **Tabla 2**, **Tabla 3** y **Tabla 4**, es posible implementar este modelo en Python, mediante el entorno de PuLP, para obtener una solución. Este modelo, que viene recopilado en el **ANEXO A**: presenta el código desarrollado para la resolución mediante el solver por defecto de PuLP.

5 ANÁLISIS DE LOS RESULTADOS

5.1 Demanda Anualizada

Para poder resolver el modelo esperado, y obtener una solución concreta que proporcionar el cliente sobre cuántos vehículos y desde qué fábrica cada año debería proporcionar, es necesario un estudio previo de estimación de la demanda. A partir de la teoría desarrollada en el apartado 3.3, y haciendo uso de los datos presentados en el apartado 4.1, en este apartado se realiza una estimación de los datos de demanda esperados.

Para ello, únicamente se hará uso de los últimos cinco años de la serie temporal extraída de ACEA [32], pues se considera que la tendencia y estacionalidad de estos años, por su cercanía y la rapidez de transformación del sector, puede ser más representativa. El año 2020 se considera como año no representativo, debido a las casuísticas del mismo -pandemia del la COVID-19- que alteran la demanda [33]. Por tanto, mediante los gráficos de la **Figura 5.1** se realizará una predicción mediante el modelo Holt-Winters, teniendo después en consideración los datos y previsiones de la **Tabla 3**, **Tabla 4** y **Tabla 6**. Previsiones para los **próximos cuatro años** -con inicio en la serie en 2021- de coches eléctricos respecto del total de matriculaciones.

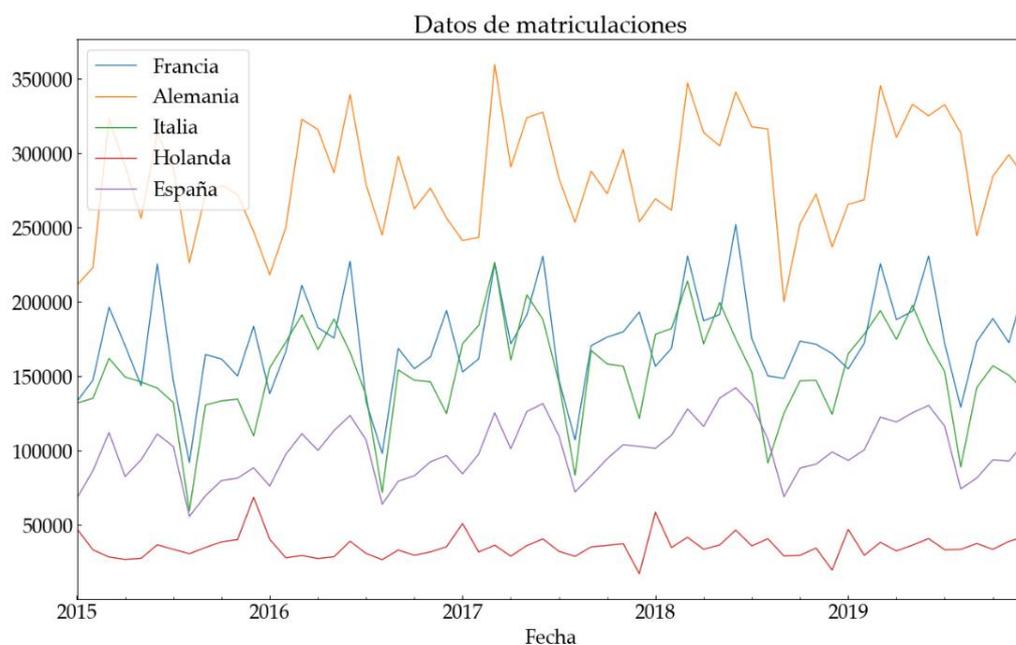


Figura 5.1. Datos históricos de matriculaciones en los últimos 5 años en los diferentes países de estudio, según los datos de ACEA [32].

Mediante el código presentado en el **ANEXO B**: se ha realizado la estimación de la demanda de vehículos eléctricos para los próximos 5 años. Pese a que el año 2020 se estima sin aplicar ningún descuento por la situación actual, serán sus datos los que se consideren para el año 2021. De esta forma, 2020 será 2021, y así sucesivamente hasta que el año 2024 contenga los datos del 2023, para las estimaciones de Holt-Winter, realizada en cada uno de los países (ver **Figura 5.2**, **Figura 5.3**, **Figura 5.4**, **Figura 5.5** y **Figura 5.6**).

Para estas estimaciones, las siguientes gráficas representan el conjunto de datos histórico de cada país, coloreado en azul como título en la leyenda "Histórico". Mediante el método Holt-Winters de statsmodels, se ha empleado estos datos para realizar un test del modelo y comprobar que era capaz de predecir el pasado de forma aproximada - coloreado en naranja como título en la leyenda "Ajuste del predictor"- . Una vez se tienen resultados que aproximan el comportamiento pasado, se ha realizado con frecuencia mensual para los próximos 5 años. Esta puede apreciarse para cada país coloreada en verde, referenciada en la leyenda como "Predicción".

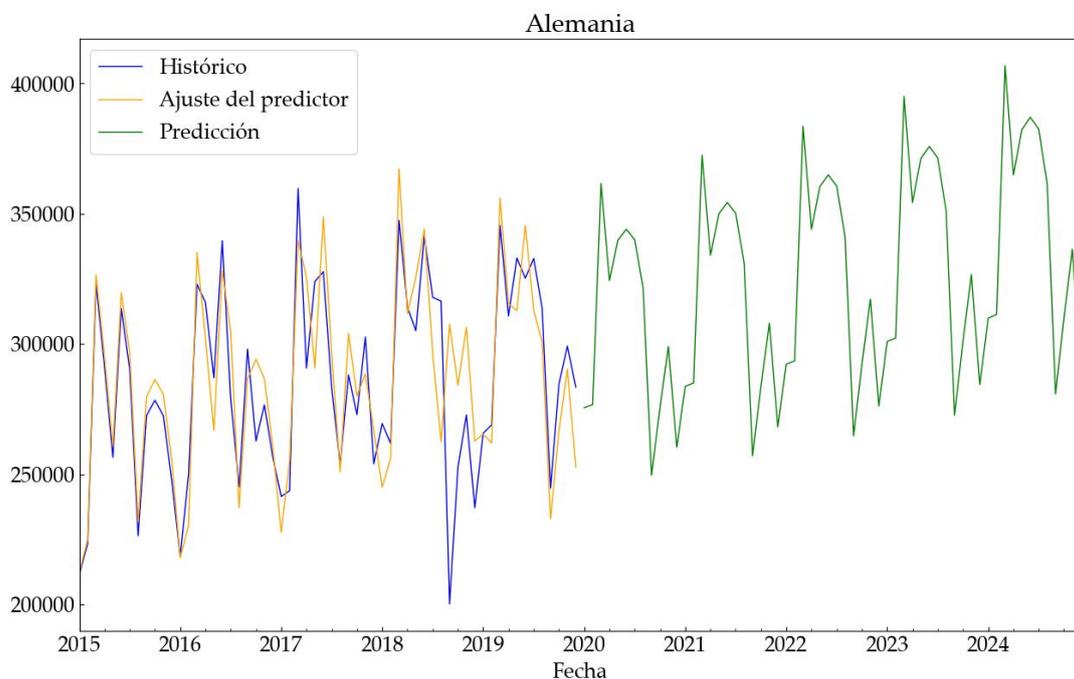


Figura 5.2. Predicción para los próximos 5 años en Alemania a partir de los últimos 5 años históricos, empleando el método Holt-Winters.

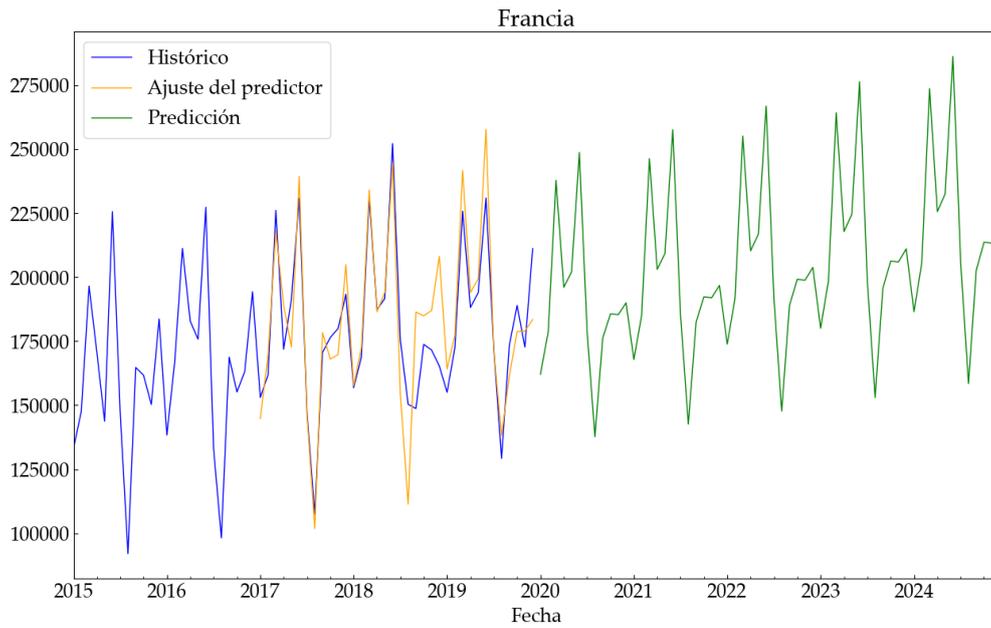


Figura 5.3. Predicción para los próximos 5 años en Francia a partir de los últimos 5 años históricos, empleando el método Holt-Winters.

Tanto para el caso de Alemania (ver **Figura 5.2**) como en el de Francia (ver **Figura 4.3**), se observa una predicción con tendencia alcista, de mayor inclinación para Alemania, y con una fuerte estacionalidad que para el caso de Francia genera dos picos. En el caso de Alemania, la estacionalidad conglomerada más meses de alta demanda.

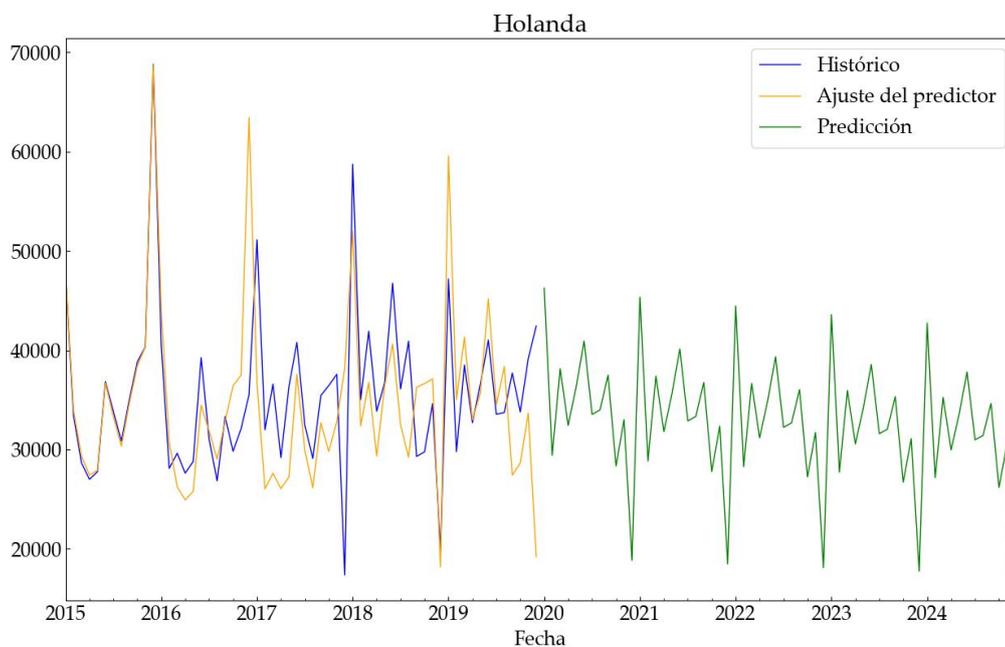


Figura 5.4. Predicción para los próximos 5 años en Holanda a partir de los últimos 5 años históricos, empleando el método Holt-Winters.

Para el caso anterior de Holanda (ver **Figura 5.4**), se observa un comportamiento diferente, con tendencia descendente y una estacionalidad con mayor ruido. Esta estacionalidad puede estar debida a cierta distorsión de los datos históricos, que complican el ajuste del modelo. No ocurre así con Italia y España, donde los datos presentan nuevamente una tendencia ascendente y marcada estacionalidad (ver **Figura 5.5** y **Figura 5.6**).

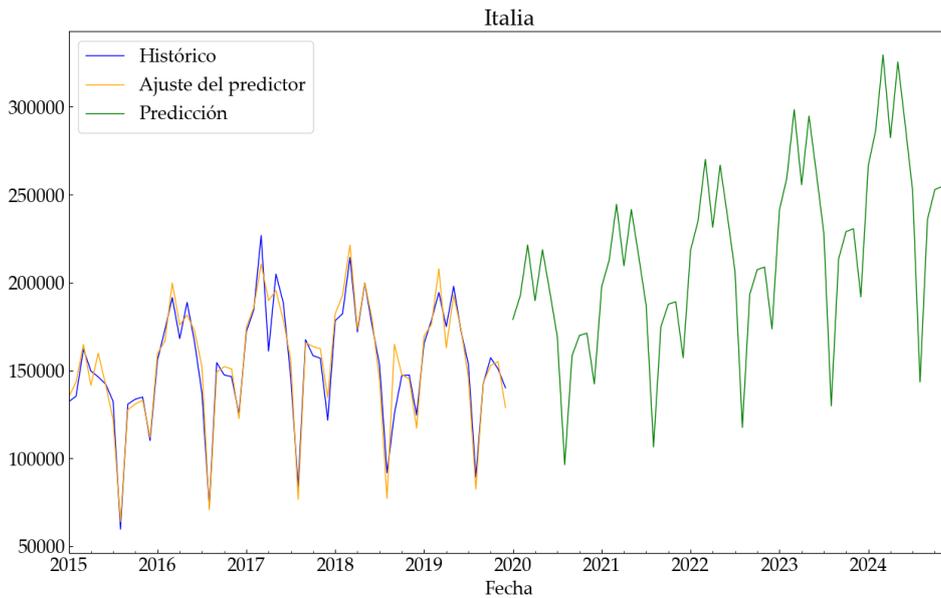


Figura 5.5. Predicción para los próximos 5 años en Italia a partir de los últimos 5 años históricos, empleando el método Holt-Winters.

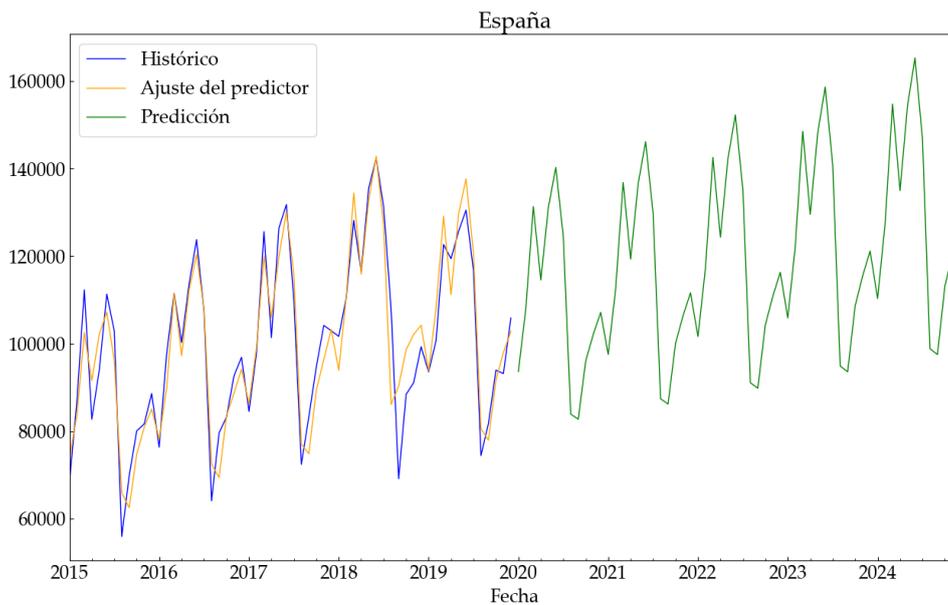


Figura 5.6. Predicción para los próximos 5 años en España a partir de los últimos 5 años históricos, empleando el método Holt-Winters.

Así, una vez almacenados los datos mensuales de la estimación, considerando que el año 2020 será 2021, y las previsiones de la **Tabla 6** para la tasa porcentual respecto del total que se esperaba fueran eléctricos, se puede obtener el número de vehículos eléctricos esperado para cada país se aproximarán a lo recogido en la **Tabla 7**.

Tabla 7. Demanda total estimada de cada uno de los países de estudio, según las consideraciones abordadas, para los próximos cuatro años.

Año	Francia	Alemania	Holanda	Italia	España
2021	57738	93230	57173	18340	15442
2022	73942	125517	67577	27598	21228
2023	91204	159689	78259	38592	27471
2024	109631	195792	88496	51555	34216

Teniendo en cuenta las cuotas de mercado que ECOCar Inc. desea ocupar en cada uno de los países, según los datos de la **Tabla 3** y **Tabla 4**, en la **Tabla 8** se recoge el número de vehículos que, para cada año, en total, ECOCar Inc. se propone vender para cada país. Para el caso de España, donde mayor detalle es requerido, se tiene la **Tabla 9**. Esto supondría cumplir sus objetivos estratégicos. Acumulados los anuales, los vehículos que cada año fabricaría para este el mercado europeo ECOCar Inc se recogen en la **Tabla 10**.

Tabla 8. Demanda de vehículos esperada por ECOCar Inc. para los diferentes países a lo largo de los 4 años de estudio.

Demanda anual	España	Alemania	Francia	Italia	Holanda
2021	3860	0	2887	917	0
2022	6368	6276	7394	2760	3379
2023	9615	15969	18241	9648	11739
2024	13686	29369	27408	15466	17699

Tabla 9. Demanda esperada detallada de las diferentes ciudades de España según los datos del estudio.

Demanda anual	Madrid	Barcelona	Sevilla	Valencia	Bilbao
2021	2123	965	193	386	193
2022	3503	1592	318	637	318
2023	5288	2404	481	961	481
2024	7527	3422	684	1369	684

Tabla 10. Demanda de vehículos eléctricos acumulados y sin redondear para fabricar por ECOCar Inc.

Año	Acumulado
2021	7664
2022	26177
2023	65212
2024	103628

De esta forma, y considerando que el modelo se realizará considerando miles de unidades, se ha decidido aproximar aquellas demandas de más de 500 unidades a 1 ud de miles de unidades. Para los casos inferiores a 500 unidades, se considerará 0 ud de miles de unidades. De esta forma, se permite simplificar la resolución del modelo de Programación Lineal. Los resultados finales introducidos al modelo se recogen finalmente en la **Tabla 11**.

Tabla 11. Previsión anual de demanda según región, durante los cuatro años de estrategia planteada.

Demanda anual	Madrid	Barcelona	Sevilla	Valencia	Bilbao	Alemania	Francia	Italia	Holanda
Año 1 (miles ud)	2	1	0	0	0	0	3	1	0
Año 2 (miles ud)	4	2	0	1	0	6	7	3	3
Año 3 (miles ud)	5	2	0	1	0	16	18	10	11
Año 4 (miles ud)	8	3	1	1	1	30	27	15	18

5.2 Resolución Del Modelo De Optimización

Una vez se conoce con detalle el conjunto de datos del modelo desarrollado en términos matemáticos en el apartado 2.1), en este apartado se analizan los datos proporcionados por el cliente, así como resolver la implementación abordada en Python. El modelo, desarrollado mediante el entorno proporcionado por PuLP y anteriormente presentado en el apartado 4.1, se encuentra en detalle en el **ANEXO A**: Mediante este, resulta una función objetivo sujeta al conjunto de 99 restricciones, con 360 variables de decisión, de las que 36 son binarias y las otras 324 de tipo entero.

Previo a comentar los resultados obtenidos de la simulación del caso de estudio, conviene evaluar previamente los datos de las tablas aportadas por el cliente (ver **Tabla 2**, **Tabla 3** y **Tabla 4**). De esta forma, se permite comprender mejor la complejidad que tiene la resolución de este tipo de sistemas, así como las primeras impresiones engañosas que pueden proporcionar si se analizan los datos de forma sesgada. En el primer caso, si se observan los costes asociados a la adquisición de cada una de las fábricas (ver **Figura 5.7**), se pueden observar grandes diferencias entre la fábrica más cara de adquirir, Houston, y las más baratas, Marruecos y Mumbai, conjuntamente. Esto está relacionado con la situación de cada una de las fábricas respecto a su relación con ECOCar Inc. La situación actual, recopilada para cada caso en la columna *Situación actual* de la **Tabla 2**, puede tomar los siguientes valores:

- A: propiedad de la compañía.
- B: requiere compra de fábrica y maquinaria de fabricación.
- C: requiere compra de fábrica, pero se encuentra equipada.

Intuitivamente, podría resultar lo más razonable emplear las fábricas ya disponibles en lugar de aquellas que deban comprarse, y en caso de deber desembolsar la compra, buscar aquellas más baratas. Sin embargo, las fábricas acarrear muchos más costes asociados que deben considerarse, como el unitario de fabricación, los costes fijos de operación y los costes logísticos a cada región de demanda.

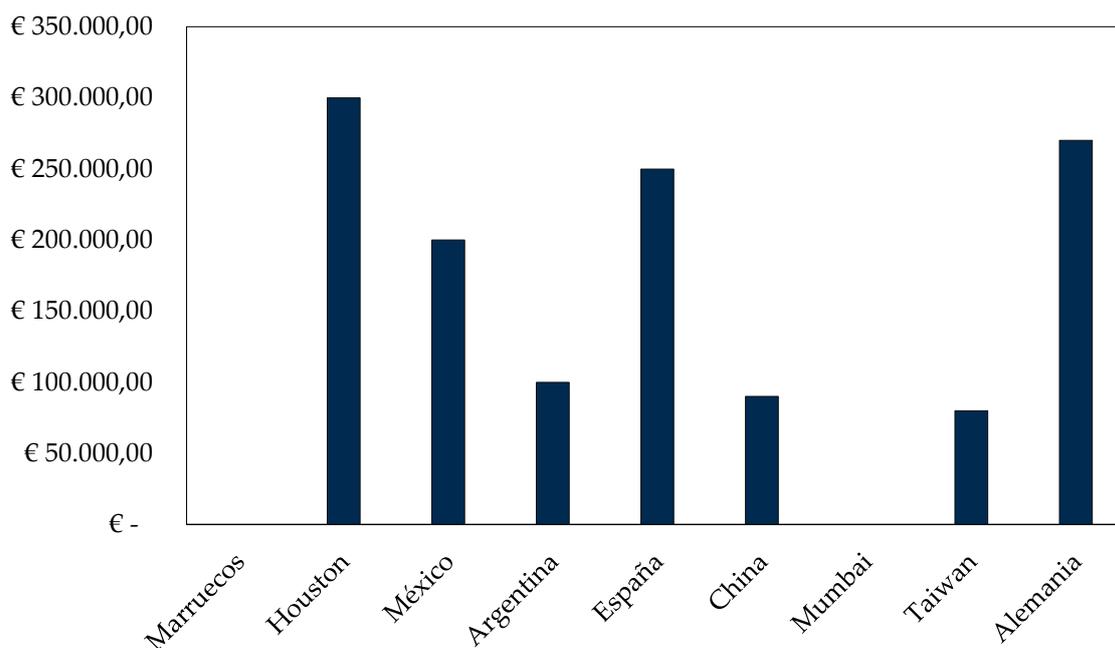


Figura 5.7. Coste inicial de adquisición para el comienzo de uso de las diferentes fábricas a las que tiene acceso directo o potencial ECOCar Inc.

Si se observa en detalle la **Figura 5.7**, se encuentra una gran diferencia entre los costes iniciales para las diferentes fábricas, de hasta 300000 €, en el caso extremo. En aquellos casos de coste cero, las fábricas corresponden con la letra A de la columna *Situación actual* de la **Tabla 2**, que tal como se anticipaba en el párrafo anterior, alude a que la fábrica ya está disponible y es operativa para la compañía. En estos casos, aunque actualmente la fábrica se emplea en otros mercados, reservan la capacidad indicada en la misma tabla para la entrada en nuevos mercados. En el caso de Argentina, China y Taiwan, que tienen los 3 siguientes costes más pequeños, representa el conjunto anteriormente agrupado en la letra C. El resto, forma el conjunto de las fábricas cuya situación actual se identifica con la letra B.

Ateniendo ahora a los costes más elevados, Houston sería la fábrica con mayor desembolso requerido inicial, seguida por Alemania y España, respectivamente. España y Alemania cuentan con regiones de demanda, por lo que aunque el coste inicial es mayor que el resto, es también probable que dependiendo de la influencia del coste unitario de cada vehículo eléctrico pudiera resultar seleccionable. Un factor fundamental, tal como se muestra posteriormente en la **Tabla 4**, será el coste logístico de

enviar desde la fábrica hasta la región de demanda. Para ello, la **Figura 5.8** complementa visualmente una comparación entre los costes fundamentales asociados a cada fábrica, sin considerar las regiones de demanda. Se observa cómo Marruecos y Mumbai presentan estos tres costes en niveles más bajos que el resto de localizaciones, mientras que Houston, Alemania y España tienen costes altos en los tres conjuntos.

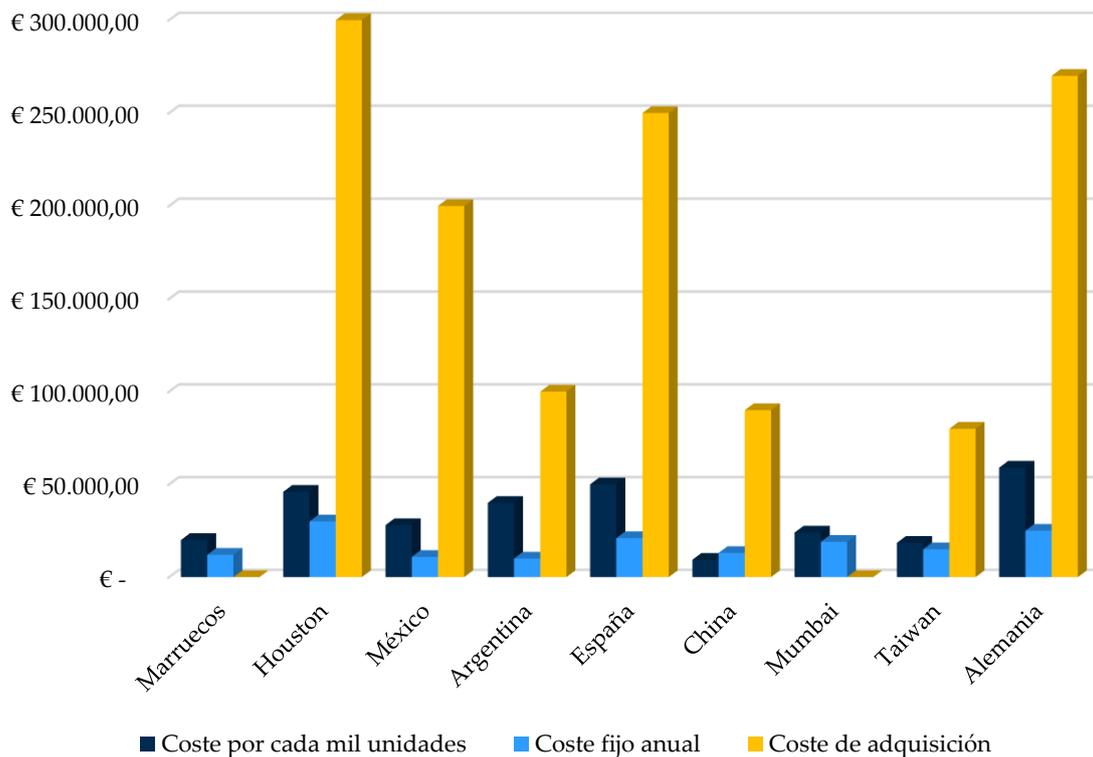


Figura 5.8. Costes fundamentales asociados a la fabricación en las distintas localizaciones disponibles de ECOCar Inc. Información relativa a la **Tabla 2**.

Uno de los problemas fundamentales, además de costes de envío a las diferentes regiones de demanda y las propias demandas de cada zona, es la capacidad de estas localizaciones. Pese a que los costes unitarios pueden ser muy bajos para algunas fábricas, puede que, de ser su capacidad muy reducida, no puedan compensar tanto la demanda recibida y resulte más rentable recurrir directamente a la compra de una fábrica. Para analizar esta posible situación se puede representar conjuntamente la capacidad de cada fábrica junto con el coste de producir cada mil unidades de vehículos eléctricos (ver **Figura 5.9**).

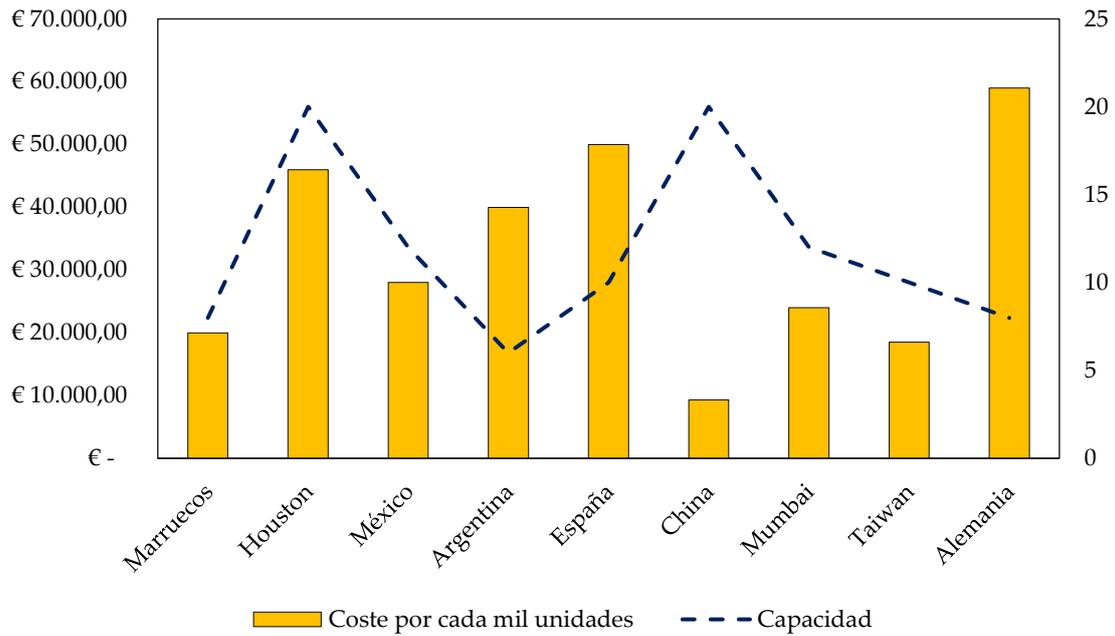


Figura 5.9. Capacidad (en miles de unidades) frente al coste asociado a la fabricación de mil unidades de vehículos (ver **Tabla 2**).

Por último, otro de los factores clave en la optimización es el coste de la logística. Este está influido por distancias, aduanas, y medios de transporte empleados, y por tanto, será diferente entre cada fábrica y cada región de demanda. Los diferentes costes, que se encuentran recopilados por cada mil unidades de vehículos eléctricos en la **Tabla 4**, pueden analizarse mejor de forma gráfica (ver **Figura 5.10**), mediante una representación de superficies. Mediante este, se puede observar cómo en la profundidad de cada región de demanda los precios logísticos según la fábrica de la que es origen el envío cambia de forma abrupta, para muchos casos.

En esta representación, puede observarse cómo en regiones de demanda como Bilbao u Holanda, los costes pueden variar en rangos entre los máximos hasta 76.000 € para el caso de Bilbao, y hasta 83.000 € para el caso de Holanda. Una clara muestra de la variabilidad del coste logístico para una misma región de demanda entre todas las posibles recepciones se muestra en la **Figura 5.11**.

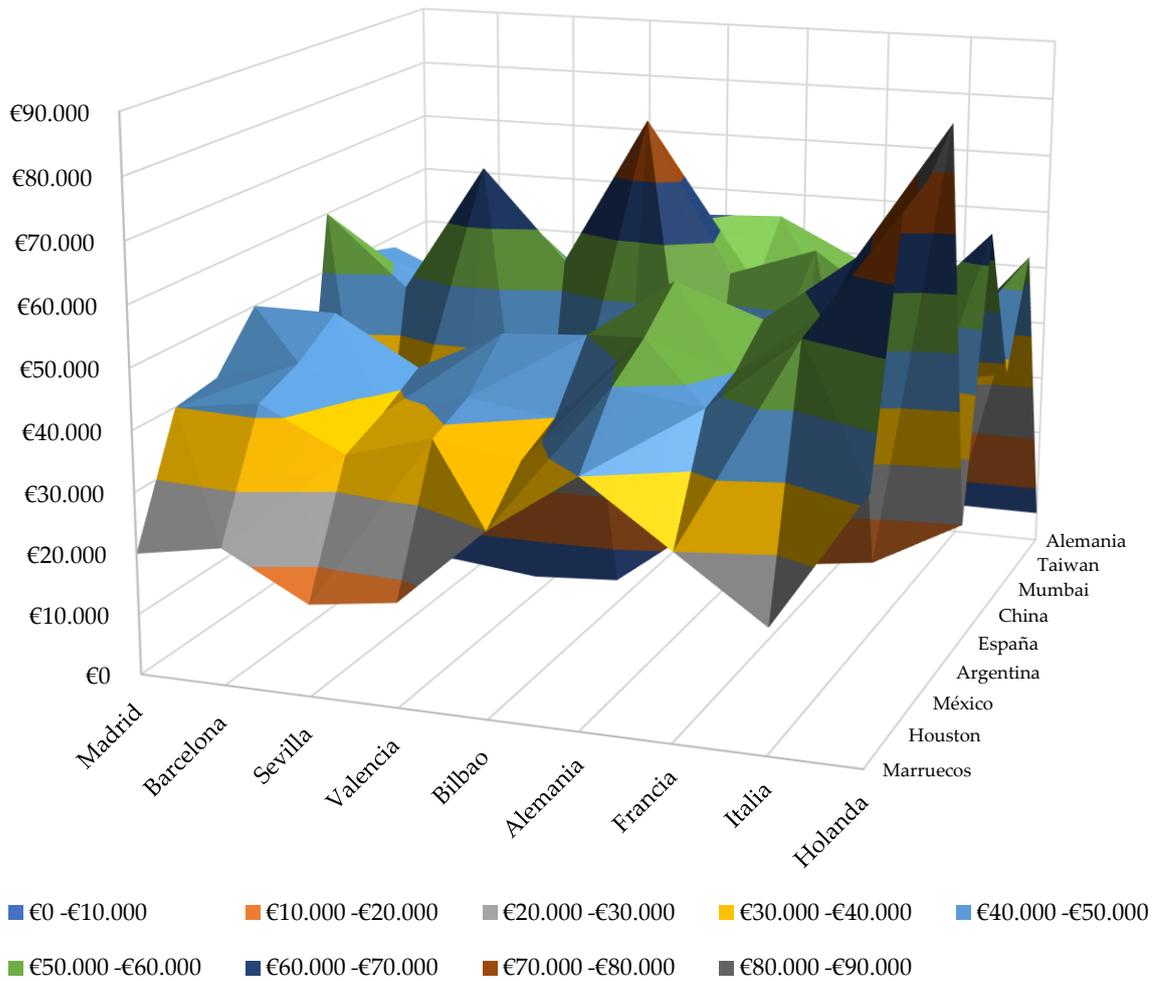


Figura 5.10. Mapa superficial de costes logísticos de recibir en una determinada región de origen respecto de una determinada fábrica (ver Tabla 4).



Figura 5.11. Comparación entre costes máximos y mínimos de logística para cada región de demanda.

Así, tras conocer más en detalle las posibilidades seleccionables del modelo y la estructura de costes asociada a cada opción, se resuelve el modelo de optimización. Bajo estas condiciones, el modelo detallado en el **ANEXO A**: converge obteniendo un valor de la función objetivo de 58.004.300,00 €. Esto supone que el solver identifica en este valor el coste logístico mínimo en el que incurriría la compañía, en condiciones ideales y sin inventario -tal como se ha realizado el modelado-, para cumplir la demanda esperada con las posibilidades proporcionadas. De esta manera, resulta posible para el cliente evaluar un coste medio de los vehículos eléctricos en función de la rentabilidad de la inversión esperada.

Además del coste mínimo, el solver proporciona qué fábricas envían a qué regiones de demanda, así como qué fábricas se deberían construir o comprar así como el año en que se debería realizar. Para recopilar los resultados obtenidos en la simulación, se emplea la siguiente **Tabla 12**:

Tabla 12. Resultados obtenidos para la simulación de minimización de la función objetivo del modelo.

Año	Región de demanda	Fábrica que lo proporciona	Cantidad enviada (en miles de ud)
1	Barcelona	China	1
1	Francia	China	3
1	Italia	China	1
1	Madrid	China	2
2	Alemania	China	6
2	Francia	China	7
2	Holanda	China	3
2	Italia	China	3
2	Valencia	China	1
2	Barcelona	Marruecos	2
2	Madrid	Marruecos	4
3	Francia	Argentina	1
3	Alemania	China	16
3	Francia	China	4
3	Barcelona	Marruecos	2
3	Madrid	Marruecos	5
3	Valencia	Marruecos	1
3	Francia	México	12
3	Francia	Mumbai	1
3	Holanda	Mumbai	11

Año	Región de demanda	Fábrica que lo proporciona	Cantidad enviada (en miles de ud)
3	Italia	Taiwan	10
4	Alemania	Alemania	6
4	Francia	Argentina	6
4	Alemania	China	20
4	Francia	España	10
4	Alemania	Houston	4
4	Bilbao	Houston	1
4	Francia	Houston	4
4	Holanda	Houston	11
4	Barcelona	Marruecos	3
4	Madrid	Marruecos	3
4	Sevilla	Marruecos	1
4	Valencia	Marruecos	1
4	Francia	México	7
4	Madrid	México	5
4	Holanda	Mumbai	7
4	Italia	Mumbai	5
4	Italia	Taiwan	10

Analizando estos datos anteriores, se obtiene qué fábricas debería abrirse o comprarse así como en qué año y a qué región deberían dar demanda para minimizar el coste. Para esta solución, se observa que el resultado proporcionado por el solver selecciona la mejor opción como comprar inicialmente una fábrica en China, y que esta suministre a la demanda completamente hasta que su capacidad se completa, en el año 2. A partir de entonces, el solver selecciona emplear la fábrica de Marruecos -construida y operativa desde el comienzo-, que cubre la demanda de Madrid y Barcelona (ver **Tabla 13**).

Pasado el segundo año, se espera una demanda mucho mayor, que hará Argentina, México, Taiwan y Mumbai. Aquí aparece un hecho relevante que no se observa en los años previos, y es que varias fábricas distribuyen a una misma región de demanda. Sucede para el caso de Francia, pues se espera una elevada demanda y la capacidad de las fábricas no es suficiente como para cubrir toda ella, y el solver identifica la combinación más barata. Para el último año, el cuarto de la estrategia propuesta, dado el alto incremento de demanda, se selecciona también España, Alemania y Houston junto al resto de fábricas anteriormente seleccionadas.

De esta forma, el solver termina seleccionando a lo largo de los cuatro años de estudio todas las fábricas disponibles, pero de forma secuenciada. Considerando costes de construcción o compra, variables de fabricación y asociados a la logística, considera desde el inicio la fábrica de China, pese a que esta debe comprarse inicialmente. Marruecos y Mumbai, que ya se disponen actualmente por la compañía, no se seleccionan hasta el año 2 y 3, respectivamente. Esto da una proyección de la importancia de los modelados en el diseño de estas redes.

Tabla 13. Fábricas y año de compra/adquisición/uso seleccionados por el solver.

Año apertura	Fábrica
1	China
2	Marruecos
3	Argentina
3	México
3	Mumbai
3	Taiwan
4	Alemania
4	España
4	Houston

Si se representa la cantidad empleada frente a la disponible de ambas fábricas durante los 4 años de estudio, se obtiene el siguiente gráfico:

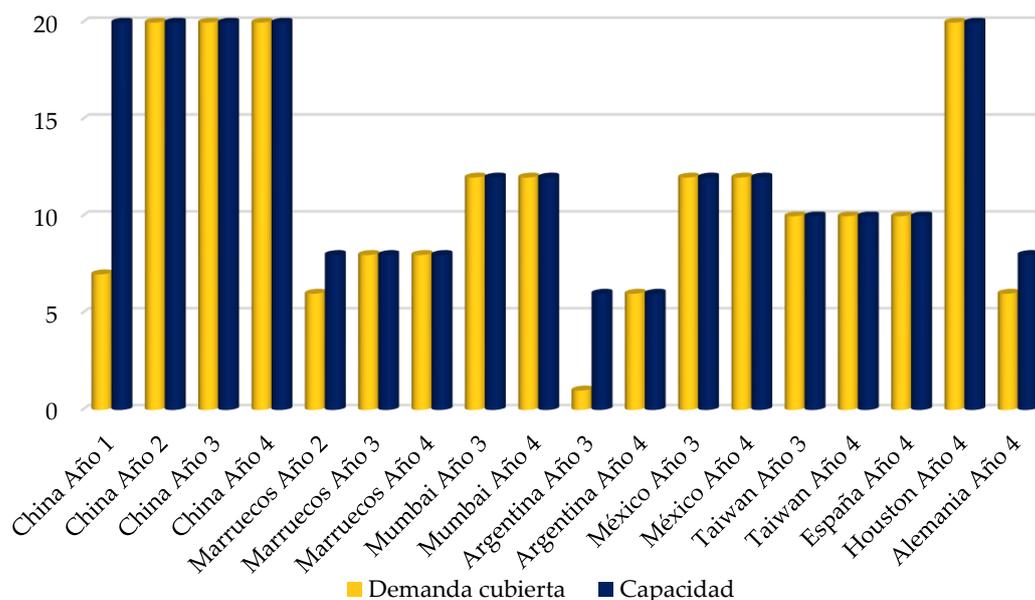


Figura 5.12. Demanda cubierta frente a capacidad (en miles de unidades) para cada una de las fábricas seleccionadas, según el año.

Siguiendo los resultados de la **Figura 5.12** anterior, se observa cómo hasta que la demanda de una nueva fábrica no está completa, no se requiere a una nueva. Esto es, hasta que la capacidad de demanda de China no está completa, no se requiere de una nueva, y no es hasta que la capacidad de Marruecos se supera, que se recurre a nuevas fábricas. Esto surge así mientras que el coste de la logística al cambiar a otra región de demanda no condiciona los precios, balanceando la dónde se produce cada demanda.

Además de la minimización de costes totales asociados a la Cadena de Suministro, se puede obtener más información sobre el beneficio de emplear este modelado mediante la maximización. Si ahora se cambia la definición del modelo mostrado en **ANEXO A**; de “`model = pl.LpProblem("TFM_Pablo_Fullana", pl.LpMinimize)`” a “`model = pl.LpProblem("TFM_Pablo_Fullana", pl.LpMaximize)`”, se obtiene el coste máximo posible de configuración del cliente, así como la selección anual que proporciona tal coste (ver **Tabla 14**).

Tabla 14. Resultados obtenidos para la simulación de maximización de la función objetivo del modelo.

Año	Región de demanda	Fábrica que lo proporciona	Cantidad enviada (en miles de ud)
1	Barcelona	Alemania	1
1	Francia	Alemania	3
1	Italia	Alemania	1
1	Madrid	Alemania	2
2	Barcelona	Alemania	2
2	Francia	Alemania	1
2	Madrid	Alemania	4
2	Valencia	Alemania	1
2	Alemania	España	6
2	Francia	España	1
2	Holanda	España	3
2	Francia	Houston	5
2	Italia	Houston	3
3	Barcelona	Alemania	2
3	Madrid	Alemania	5
3	Valencia	Alemania	1
3	Holanda	Argentina	6
3	Alemania	España	9
3	Francia	España	1
3	Francia	Houston	10

Año	Región de demanda	Fábrica que lo proporciona	Cantidad enviada (en miles de ud)
3	Italia	Houston	10
3	Francia	México	7
3	Holanda	México	5
3	Alemania	Mumbai	7
4	Madrid	Alemania	7
4	Valencia	Alemania	1
4	Holanda	Argentina	6
4	Barcelona	China	3
4	Bilbao	China	1
4	Francia	China	14
4	Alemania	España	2
4	Francia	España	8
4	Francia	Houston	5
4	Italia	Houston	15
4	Alemania	Marruecos	8
4	Holanda	México	12
4	Alemania	Mumbai	10
4	Madrid	Mumbai	1
4	Sevilla	Mumbai	1
4	Alemania	Taiwan	10

Simulando el modelo para la maximización de la función objetivo, se obtiene un coste total de 91.636.100,00 €. Esto supone que, en la peor selección posible de la configuración se tendría un coste de aproximadamente 33,6 millones de euros superior, respecto de la selección obtenida inicialmente para la minimización. De esta forma, ECOCar Inc. debería poner un coste de venta de su producto mucho mayor para obtener el % de beneficio esperado, perdiendo competitividad. Así, es fundamental optimizar la red para lograr una operativa rentable. Considerando que la demanda acumulada tras cuatro años de previsión es de 200.000 unidades de vehículos eléctricos, los costes mínimos para cubrir el coste de la cadena de suministro se muestran en la **Tabla 15**.

Tabla 15. Análisis de coste unitario y beneficios para los casos extremos resultado de la optimización.

Objetivo optimización	Coste total (€)	Coste unitario (200.000 ud)	Precio a beneficio 40%
Minimización	58.004.300,00	290,02 €	406,03 €
Maximización	91.636.100,00	458,18 €	641,45 €

Así, la **Tabla 15** proporciona una información muy ilustrativa sobre la importancia de estos estudios en el negocio. Para el peor caso de configuración, el precio de venta de cada unidad que proporcionaría el 40% de beneficio a la compañía no sería suficiente para pagar el coste unitario del peor caso de la configuración. Esto implica como decisión estratégica en la viabilidad del producto un análisis cuidadoso y un diseño optimizado de la red, en la que la demanda de cada localización proporciona información fundamental para la configuración.

6 CONCLUSIONES

Este trabajo representa la gran utilidad que la Optimización Matemática y los modelos de predicción de series temporales pueden aportar a problemas reales de negocio, mostrándose en combinación como una excepcional herramienta de decisión. De igual manera, se demuestra la importancia de obtener buenos datos, representativos de la realidad para poder realizar estimaciones con imprecisiones reducidas. Además de esto, se ha profundizado en el uso de lenguajes de programación y paquetes de optimización lineal, con el fin de simplificar la resolución de problemas que de otra forma resultarían complejos y tediosos de resolver.

Gracias al uso de los paquetes statsmodels y PuLP, se ha permitido resolver de forma rápida y automatizada el problema de negocio, mostrando la capacidad de ambas herramientas. En el modelo de Holt-Winters, como herramienta para estimar el futuro ante un conjunto fiable de datos históricos, y del modelado matemático, para resolver eficientemente el Diseño de Redes en la Cadena de Suministro. Mediante este modelo, se permite resolver de forma objetiva las soluciones óptimas ante una petición de negocio de clientes, minimizando suposiciones y obteniendo un resultado óptimo.

En cuanto al caso de estudio, se ha resuelto la demanda del cliente, proporcionándole una solución óptima para las condiciones de contorno proporcionadas, empleando todas las fábricas disponibles, pero con la secuencia más eficiente en términos de consumo de capital. El modelo tiene un diferencial de hasta 33,6 millones de euros de una decisión errónea, bajo las suposiciones consideradas, así como incrementar el beneficio unitario por cada vehículo. Se ha observado cómo el conjunto de costes asociados pueden sobrepasar las opciones inicialmente mejores, que podrían haberse considerado como las fábricas ya abiertas, o incluso comprar fábricas justo donde estaba la demanda.

Como estudios futuros, convendría considerar costes de inventario, tiempos de entrega y un detalle mensual de la demanda. Para esto, sería recomendable ajustar el modelo a la respuesta del mercado, ajustando cuándo se realizan los envíos para cubrir la estacionalidad. Esta variable podría ser de gran importancia, principalmente para tiempos de envío elevados.

BIBLIOGRAFÍA

- [1] A. E. Branch, *Global supply chain management and international logistics*, New York: Routledge. Taylor and Francis Group, 2009.
- [2] J. H. Chavez, *Supply Chain Management*, RIL Editores, 2012.
- [3] R. E. Slone, J. P. Dittmann y J. T. Mentzer, *Transformando la cadena de suministro: Innovando para la creación de valor en todos los procesos críticos*, Profit, 2012.
- [4] EV-Volumes, «ev-volumes.com,» 2019. [En línea]. Available: <http://www.ev-volumes.com/news/global-bev-phev-sales-for-2019/>. [Último acceso: 04 04 2020].
- [5] McKinsey&Company, «Race 2050 - A vision for the european automotive industry,» McKinsey&Company, 2019.
- [6] OVEMS - Universidad Pontificia Comillas, «Evobservatory,» 2019. [En línea]. Available: <https://evobservatory.iit.comillas.edu/#easy-footnote-bottom-11-224>. [Último acceso: 26 Marzo 2020].
- [7] P. Frías y J. Román, «Vehículo eléctrico: situación actual y perspectivas futuras,» *Economía Industrial*, nº 411, pp. 11-20, 2019.
- [8] McKinsey&Company, «The global electric-vehicle market is amped up and on the rise,» McKinsey&Company, 2018.
- [9] J. Roussel y S. Cohen, *Strategic supply chain*, McGraw Hill, 2004.
- [10] S. Chopra y P. Meindl, *Administración de la cadena de suministro: Estrategia, Planeación y Operación*, México: Pearson Educación, 2008.
- [11] D. J. Bowersox, D. J. Closs y M. B. Cooper, *Supply chain logistics management*, McGraw Hill, 2001.
- [12] J. C. Treviño y A. Bauza, «Visión Industrial,» 07 07 2017. [En línea]. Available: <https://www.visionindustrial.com.mx/industria/noticias/fraudes-en-la-cadena-de-suministro-cuatro-pasos-basicos-para-prevenirlos>. [Último acceso: 12 05 2020].
- [13] M. L. Fisher, «What is the right Supply Chain for your product?,» *Harvard Business Review*, pp. 83-93, 1997.

- [14] D. N. Wilke y J. A. Snyman, Practical mathematical optimization. An introduction to basic optimization theory and classical and new gradient-based algorithms, Springer, 2005.
- [15] M. Minoux, Mathematical programming theory and algorithms, John Wiley & Sons, 1986.
- [16] F. H. a. G. Lieberman, Introducción a la investigación de operaciones, McGraw Hill, 2001.
- [17] W. L. Winston, Operations research: applications and algorithms, International Thomson Publishing, 1994.
- [18] M. M. Maestre, «Técnicas clásicas de optimización. Parte 1: Programación Lineal y No Lineal,» UPV/EHU.
- [19] S. G. Paredes, «Tema 1. Fundamentos de optimización,» UPCT.
- [20] M. d. C. Martínez-Blázquez, «Tema 1: Introducción a la Investigación Operativa,» UPV, Valencia.
- [21] Linear programming: Mathematics, Theory and Algorithms Michael J. Panik, Kluwer Academic Publishers, 2012.
- [22] G. B. Dantzig, Linear programming and extensions, Princeton University Press, 1959.
- [23] beseeyong, «Steemit,» [En línea]. Available: <https://steemit.com/kr-steemit/@beseeyong/best-python-libraries-packages-for-finance-and-financial-data-scientists-numerical-statistical-and-data-structures>. [Último acceso: 12 04 2020].
- [24] CVXopt, «CVXopt,» [En línea]. Available: <https://cvxopt.org/>. [Último acceso: 12 04 2020].
- [25] Pyomo, «Pyomo,» [En línea]. Available: <http://www.pyomo.org/>. [Último acceso: 12 04 2020].
- [26] C. E. Catalán, «Index of /cchs/web_UAE/tutoriales/PDF,» 11 03 2010. [En línea]. Available: http://humanidades.cchs.csic.es/cchs/web_UAE/tutoriales/PDF/. [Último acceso: 23 05 2020].

- [27] J. M. M. Diazaraque, «Departamento de Estadística UC3M,» [En línea]. Available: <http://halweb.uc3m.es/esp/Personal/personas/jmmarin/esp/EDescrip/tema7.pdf>. [Último acceso: 23 05 2020].
- [28] D. Peña, *Análisis de series temporales*, Alianza Editorial, 2010.
- [29] R. J. Hyndman y G. Athanasopoulos, *Forecasting: Principales and practice*, Australia: OTexts, 2018.
- [30] S. Makridakis, S. C. Wheelwright, R. J. Hyndman y N. Hoboken, *Forecasting: methods and applications*, John Wiley & Sons, 1998.
- [31] D. C. Montgomery, C. L. Jennings y M. Kulahci, *Introduction to time series analysis and forecasting*, John Wiley & Sons, 2008.
- [32] M. G. Velasco y I. M. d. P. García, *Series temporales*, Universidad de Extremadura, 2009.
- [33] ostigov, «Engineering Statistics Handbook,» [En línea]. Available: <https://www.itl.nist.gov/div898/handbook/pmc/section4/pmc421.htm>. [Último acceso: 03 06 2020].
- [34] C. C. Holt, «Forecasting seasonals and trends by exponentially weighted averages,» *International Journal of Forecasting*, vol. 20, nº 1, pp. 5-10, 1957.
- [35] P. R. Winters, «Forecasting sales by exponentially weighted moving averages,» *Management Science*, vol. 6, nº 3, pp. 324-342, 1960.
- [36] T.-M. Choi, Y. Yu y K.-F. Au, «A hybrid SARIMA wavelet transform method for sales forecasting,» *Decision Support Systems*, vol. 51, nº 1, pp. 130-140, 2011.
- [37] Duke University, «People Duke,» [En línea]. Available: <https://people.duke.edu/~rnau/411sdif.htm>. [Último acceso: 04 06 2020].
- [38] J. Perktold, S. Seabold y J. Taylor, «statsmodels,» 21 02 2020. [En línea]. Available: <https://www.statsmodels.org/stable/index.html>. [Último acceso: 04 06 2020].
- [39] J. Hunter, D. Dale, E. Firing y M. Droettboom, «matplotlib,» 08 04 2020. [En línea]. Available: <https://matplotlib.org/>. [Último acceso: 04 06 2020].
- [40] ACEA, «ACEA - European Automobile Manufacturers' Association,» [En línea]. Available: <https://www.acea.be/>. [Último acceso: 25 05 2020].

- [41] F. García, «El automóvil perderá un 25% de su producción por el coronavirus,» *Expansión*, 24 04 2020.
- [42] Pandas, «pandas.pydata.org,» [En línea]. Available: https://pandas.pydata.org/pandas-docs/stable/getting_started/dsintro.html. [Último acceso: 05 05 2020].
- [43] M. Hugos, *Essentials of Supply Chain Management, Third Edition ed.*, Hoboken, New Jersey.: John Wiley & Sons, Inc, 2011.
- [44] J. L. Cavinato, «What's your Supply Chain type?,» *Supply Chain Management Review*, pp. 60-66, 2002.
- [45] ElPeriodicodelaEnergia, «Elperiodicodelaenergia.com,» 02 08 2018. [En línea]. Available: <https://elperiodicodelaenergia.com/mckinsey-advierte-de-que-habra-muchos-coches-electricos-pero-no-donde-cargarlos/>. [Último acceso: 04 04 2020].
- [46] J. C. García, *Predicción en el dominio del tiempo: análisis de series temporales para ingenieros*, Valencia: Universidad Politécnica de Valencia, 2016.

ANEXO A: CÓDIGO DE LA ESTIMACIÓN DE LA DEMANDA

En el presente anexo, se recopila el código desarrollado para la predicción mediante el método Holt-Winters de las matriculaciones de coches para los próximos 5 años. A partir del conjunto de datos extraído de ACEA [32], se ha realizado un documento csv reducido de datos, desde el año 2015, denominado `'historicos_matriculaciones_pred.csv'`.

En este código se realiza tanto una representación gráfica de todos los datos, que puede observarse en la **Figura 5.1**, como el modelado, entrenamiento y predicción para todos los países. Para ajustar los parámetros del modelo Holt-Winters, se emplea el DataFrame `test_pais`, que es el conjunto de datos proporcionado a la variable `model_pais`, que entrena el modelo. A partir de `pred_test_pais`, representando gráficamente sus datos respecto los históricos originales, se comprueba gráficamente cómo de preciso este modelo replica el pasado. En el caso de que los resultados sean satisfactorios, se puede confiar en el modelo para realizar la predicción. Para realizar la predicción, se define la variable `pred_forecast_pais`.

Las predicciones en ExponentialSmoothing del módulo `holtwinters` de `Statsmodels` únicamente requieren, tras definir el modelo, saber el punto de partida y el punto final. Dado que la frecuencia está definida mediante la sentencia `df_matric = df_matric.set_index('Fecha').asfreq('MS')` como mensual, únicamente basta con indicar las fechas inicio y fin de la predicción. En caso de no tener un modelo tan definido, se podría también hacer uso de la función `forecast` del módulo. Esta función únicamente requiere conocer los pasos que se requiere predecir.

```
import pandas as pd
import matplotlib.pyplot as plt
from statsmodels.tsa.holtwinters import ExponentialSmoothing

# Configuramos el defecto de las graficas.
plt.rcParams.update({'font.size': 18, 'font.family': 'Palatino Linotype', 'lines.linewidth': 1
                    , 'axes.labelsize':18, 'xtick.direction': 'in', 'ytick.direction': 'in', 'legend.fontsize': 18,
                    'legend.frameon': True, 'figure.figsize': (14, 10)})
```

```
# Leemos los datos y seleccionamos una frecuencia mensual
df_matric = pd.read_csv('historicos_matriculaciones_pred.csv')
df_matric['Fecha'] = pd.to_datetime(df_matric['Fecha'], format='%b-%y')
df_matric = df_matric.set_index('Fecha').asfreq('MS')

# Dataframe para almacenar la prediccion
# results = pd.DataFrame(data = )

# Ploteamos todos los datos juntos
df_matric.plot(figsize=(15,9), label='Histórico')
plt.title('Datos de matriculaciones')
plt.legend()
plt.savefig('Figures\lldata.png')
plt.show()

# FRANCIA
# Dividimos datos en los de entrenamiento y los del test
train_fr = df_matric['Francia'].loc[:'2019-10-01']
test_fr = df_matric['Francia'].loc['2019-10-01':]

# Definimos el modelo, generamos el testeo y predecimos
model_fr = ExponentialSmoothing(train_fr, trend='mul', sea-
sonal='mul', seasonal_periods=12).fit()
pred_test_fr = model_fr.predict(start='2017-01-01', end='2019-12-01')
pred_forecast_fr = model_fr.predict(start='2020-01-01', end='2024-12-01')

# Representamos histórico, entrenamiento y prediccion
plt.title('Francia')
df_matric['Francia'].plot(figsize=(15,9), label='Histó-
rico', color = 'blue')
pred_test_fr.plot(label='Ajuste del predictor', color = 'orange')
pred_forecast_fr.plot(label='Predicción', color = 'green')
plt.legend()
plt.savefig('Figures\Francia.png')
plt.show()

# ALEMANIA
# Dividimos datos en los de entrenamiento y los del test
train_al = df_matric['Alemania'].loc[:'2019-10-01']
test_al = df_matric['Alemania'].loc['2019-10-01':]

# Definimos el modelo, generamos el testeo y predecimos
model_al = ExponentialSmoothing(train_al,trend='mul', sea-
sonal='mul', seasonal_periods=12).fit()
pred_test_al = model_al.predict(start='2015-01-01', end='2019-12-01')
pred_forecast_al = model_al.predict(start='2020-01-01', end='2024-12-01')

# Representamos histórico, entrenamiento y prediccion
```

```

plt.title('Alemania')
df_matric['Alemania'].plot(figsize=(15,9), label='Histórico', color = 'blue')
pred_test_al.plot(label='Ajuste del predictor', color = 'orange')
pred_forecast_al.plot(label='Predicción', color = 'green')
plt.legend()
plt.savefig('Figures\Alemania.png')
plt.show()

# ITALIA
# Dividimos datos en los de entrenamiento y los del test
train_it = df_matric['Italia'].loc[:'2019-10-01']
test_it = df_matric['Italia'].loc['2019-10-01':]

# Definimos el modelo, generamos el testeo y predecimos
model_it = ExponentialSmoothing(train_it,trend='mul', seasonal='mul', seasonal_periods=12).fit()
pred_test_it = model_it.predict(start='2015-01-01', end='2019-12-01')
pred_forecast_it = model_it.predict(start='2020-01-01', end='2024-12-01')

# Representamos histórico, entrenamiento y prediccion
plt.title('Italia')
df_matric['Italia'].plot(figsize=(15,9), label='Histórico', color = 'blue')
pred_test_it.plot(label='Ajuste del predictor', color = 'orange')
pred_forecast_it.plot(label='Predicción', color = 'green')
plt.legend()
plt.savefig('Figures\Italy.png')
plt.show()

# HOLANDA
# Dividimos datos en los de entrenamiento y los del test
train_hol = df_matric['Holanda'].loc[:'2019-10-01']
test_hol = df_matric['Holanda'].loc['2019-10-01':]

# Definimos el modelo, generamos el testeo y predecimos
model_hol = ExponentialSmoothing(train_hol,trend='mul', seasonal='mul', seasonal_periods=12).fit()
pred_test_hol = model_hol.predict(start='2015-01-01', end='2019-12-01')
pred_forecast_hol = model_hol.predict(start='2020-01-01', end='2024-12-01')

# Representamos histórico, entrenamiento y prediccion
plt.title('Holanda')
df_matric['Holanda'].plot(figsize=(15,9), label='Histórico', color = 'blue')
pred_test_hol.plot(label='Ajuste del predictor', color = 'orange')
pred_forecast_hol.plot(label='Predicción', color = 'green')
plt.legend()

```

```
plt.savefig('Figures\Holanda.png')
plt.show()

# ESPANA
# Dividimos datos en los de entrenamiento y los del test
train_sp = df_matric['España'].loc[:'2019-10-01']
test_sp = df_matric['España'].loc['2019-10-01':]

# Definimos el modelo, generamos el testeo y predecimos
model_sp = ExponentialSmoothing(train_sp,trend='mul', seasonal='mul', seasonal_periods=12).fit()
pred_test_sp = model_sp.predict(start='2015-01-01', end='2019-12-01')
pred_forecast_sp = model_sp.predict(start='2020-01-01', end='2024-12-01')

# Representamos histórico, entrenamiento y prediccion
plt.title('España')
df_matric['España'].plot(figsize=(15,9), label='Histórico', color = 'blue')
pred_test_sp.plot(label='Ajuste del predictor', color = 'orange')
pred_forecast_sp.plot(label='Predicción', color = 'green')
plt.legend()
plt.savefig('Figures\Spain.png')
plt.show()

# Guardamos las predicciones para exportarlas
results = pd.DataFrame()
results['Francia'] = pred_forecast_fr
results['Alemania'] = pred_forecast_al
results['Holanda'] = pred_forecast_hol
results['Italia'] = pred_forecast_it
results['Spain'] = pred_forecast_sp

result = results.astype('int64', copy=False)
result.to_csv('prediccion_resultados.csv')
```

ANEXO B: CÓDIGO DEL MODELADO DE LA OPTIMIZACIÓN

En el presente anexo, se recopila el código del modelado en Python del modelado matemático anteriormente desarrollado en la sección 4.1. Para la implementación, se ha hecho uso del lenguaje de programación Python, así como el paquete de optimización lineal “PuLP”, descrito previamente en la sección **Optimización mediante entornos de programación**.

De igual forma, para facilitar la estructura del código y proporcionar los datos del modelo, se ha hecho uso de documentos de tipo .csv (ver **Tabla 16** y **Tabla 17**). Para poder cargar esta información y ejecutar el modelo, se ha empleado el paquete Pandas - biblioteca de código abierto que proporciona estructuras de datos y herramientas de análisis de datos para el lenguaje de programación Python-, que contiene diversas funciones para cargar archivos .csv así como trabajar con ellos. Los conjuntos de datos exportados desde los archivos .csv, se convierten a “DataFrames”, para facilitar su uso. En el lenguaje de programación Python, un DataFrame es una estructura de datos de 2 dimensiones, con columnas de tipos potencialmente diferentes, según la descripción realizada oficialmente por los desarrolladores de Pandas [32].

Tabla 16. Conjunto de datos de demanda recopilados en el archivo .csv de demanda por Región y año.

Year	Region	Demanda
1	Madrid	2
1	Barcelona	1
1	Valencia	0
1	Sevilla	0
1	Bilbao	0
1	Alemania	0
1	Francia	3
1	Italia	1
1	Holanda	0
2	Madrid	4
2	Barcelona	2
2	Valencia	1
2	Sevilla	0
2	Bilbao	0
2	Alemania	6
2	Francia	7
2	Italia	3

Year	Region	Demanda
2	Holanda	3
3	Madrid	5
3	Barcelona	2
3	Valencia	1
3	Sevilla	0
3	Bilbao	0
3	Alemania	16
3	Francia	18
3	Italia	10
3	Holanda	11
4	Madrid	8
4	Barcelona	3
4	Valencia	1
4	Sevilla	1
4	Bilbao	1
4	Alemania	30
4	Francia	27
4	Italia	15
4	Holanda	18

Tabla 17. Conjunto de datos en el archivo .csv de coste de ruta para las diferentes combinaciones desde una determinada fábrica a cada región de demanda.

Fabrica	Region	Coste envio
Marruecos	Madrid	20000
Marruecos	Barcelona	22500
Marruecos	Valencia	17000
Marruecos	Sevilla	15000
Marruecos	Bilbao	30000
Marruecos	Alemania	40000
Marruecos	Francia	30000
Marruecos	Italia	20000
Marruecos	Holanda	42000
Houston	Madrid	40000
Houston	Barcelona	42000
Houston	Valencia	39000
Houston	Sevilla	35000
Houston	Bilbao	37000
Houston	Alemania	50000
Houston	Francia	48000
Houston	Italia	60000
Houston	Holanda	42000
Mexico	Madrid	41200
Mexico	Barcelona	45000

Fabrica	Region	Coste envio
Mexico	Valencia	42000
Mexico	Sevilla	38000
Mexico	Bilbao	40000
Mexico	Alemania	54200
Mexico	Francia	50000
Mexico	Italia	61000
Mexico	Holanda	82000
Argentina	Madrid	50000
Argentina	Barcelona	50000
Argentina	Valencia	49000
Argentina	Sevilla	42000
Argentina	Bilbao	50000
Argentina	Alemania	60000
Argentina	Francia	55000
Argentina	Italia	66000
Argentina	Holanda	88000
Espana	Madrid	2000
Espana	Barcelona	4000
Espana	Valencia	3000
Espana	Sevilla	4500
Espana	Bilbao	4000
Espana	Alemania	15000
Espana	Francia	10000
Espana	Italia	12000
Espana	Holanda	20000
China	Madrid	60000
China	Barcelona	65000
China	Valencia	55000
China	Sevilla	70000
China	Bilbao	80000
China	Alemania	55000
China	Francia	60000
China	Italia	50000
China	Holanda	65000
Mumbai	Madrid	50000
Mumbai	Barcelona	43000
Mumbai	Valencia	41000
Mumbai	Sevilla	59000
Mumbai	Bilbao	61250
Mumbai	Alemania	50000
Mumbai	Francia	45000
Mumbai	Italia	35000
Mumbai	Holanda	38000
Taiwan	Madrid	48000

Fabrica	Region	Coste envio
Taiwan	Barcelona	42000
Taiwan	Valencia	40000
Taiwan	Sevilla	52000
Taiwan	Bilbao	54000
Taiwan	Alemania	59000
Taiwan	Francia	52000
Taiwan	Italia	38000
Taiwan	Holanda	55000
Alemania	Madrid	16500
Alemania	Barcelona	13500
Alemania	Valencia	18000
Alemania	Sevilla	25000
Alemania	Bilbao	15000
Alemania	Alemania	2000
Alemania	Francia	4000
Alemania	Italia	5000
Alemania	Holanda	5000

Además de estos archivos de extensión .csv, los datos de coste unitario de producción, los costes fijos anuales y los costes de compra o adquisición para cada fábrica, así como la capacidad máxima anual de cada fábrica, se han implementado en el código mediante diccionarios. Para generar las variables enteras y binarias del problema, se ha automatizado la definición mediante listas de texto que se combinan mediante la función *.dicts* al crear las variables del paquete PuLP - simplificado como *pl* en el código-, con *pl.LpVariable*.

El código del modelo cuyos resultados se analizan en **ANÁLISIS DE LOS RESULTADOS**, se muestra a continuación:

```
import pandas as pd
import pulp as pl

#Modelo bajo funcion ejecutable:
def execute():
    dem = pd.read_csv('demanda_anual.csv', index_col=['Year', 'Region'])
    demanda = pd.DataFrame(dem, columns=['Demanda'])
    cost_desplaz = pd.read_csv('coste_ruta.csv', index_col=['Fabri-
ca', 'Region'])
    coste_desplaz = pd.DataFrame(cost_desplaz)
```

```

coste_unitario = {'Marruecos': 200, 'Houston': 460, 'Mexico': 280, 'Argentina': 400, 'Espana': 500, 'China': 93,
                  'Mumbai': 240, 'Taiwan': 185, 'Alemania': 590}
coste_fijo = {'Marruecos': 12000, 'Houston': 30000, 'Mexico': 10900, 'Argentina': 10000, 'Espana': 21000, 'China': 13000,
              'Mumbai': 19000, 'Taiwan': 15000, 'Alemania': 25000}
coste_compra = {'Marruecos': 0, 'Houston': 300000, 'Mexico': 200000, 'Argentina': 100000, 'Espana': 250000, 'China': 90000,
                'Mumbai': 0, 'Taiwan': 80000, 'Alemania': 270000}
capacidad_max = {'Marruecos': 8, 'Houston': 20, 'Mexico': 12, 'Argentina': 6, 'Espana': 10, 'China': 20, 'Mumbai': 12, 'Taiwan': 10, 'Alemania': 8}

year = ['1', '2', '3', '4']
fabricante = ['Marruecos', 'Houston', 'Mexico', 'Argentina', 'Espana', 'China', 'Mumbai', 'Taiwan', 'Alemania']
reg_demanda = ['Madrid', 'Barcelona', 'Valencia', 'Sevilla', 'Bilbao', 'Alemania', 'Francia', 'Italia', 'Holanda']

unidades = pl.LpVariable.dicts("ud_enviadas",
                               [(i, j, k) for i in year for j in fabricante for k in reg_demanda],
                               lowBound=0,
                               cat=pl.LpInteger)

estadoFabrica = pl.LpVariable.dicts("Estado",
                                     [(i, j) for i in year for j in fabricante]), cat=pl.LpBinary)

model = pl.LpProblem("TFM_Pablo_Fullana", pl.LpMinimize) #Minimizar
# model = pl.LpProblem("TFM_Pablo_Fullana", pl.LpMaximize) #Maximizar

# Funcion objetivo.

model += (pl.lpSum((1000 * coste_unitario[fabrica] + coste_desplaz.loc[fabrica, region]) * unidades[(y, fabrica, region)] for y, fabrica, region in unidades.keys()) +
          pl.lpSum( (coste_compra[fabrica]) * estadoFabrica[y, fabrica] for y, fabrica in estadoFabrica.keys()) +
          pl.lpSum((coste_fijo[fabrica] * estadoFabrica[y, fabrica] for y, fabrica in estadoFabrica.keys()))
          )

# -----
# Restricciones
# -----

```

```
# Restricción: no se envían más unidades de la capacidad marcada por
año en fabrica

    for i in fabricante:
        for l in year:
            model += pl.lpSum(unidades[(l,i,j)] for j in reg_demanda) <=
capacidad_max[i] * estadoFabrica[l, i]

# Restriccion: se cubre la demanda en cada destino para cada año
for j in reg_demanda:
    for l in year:
        model += pl.lpSum(unidades[(l,i,j)] for i in fabricante) >=
demanda.loc[(float(l), str(j)), 'Demanda'] # Minimizar
        # model += pl.lpSum(unidades[(l,i,j)] for i in fabricante) ==
demanda.loc[(float(l), str(j)), 'Demanda'] # Maximizar

# Restriccion: fabrica abierta en años posteriores
for indice in range(len(year)-1):
    l = year[indice]
    for i in fabricante:
        model += estadoFabrica[l, i] <= estadoFabrica[str(int(l)+1),
i]

    model.solve()
# print(model)

for v in model.variables():
    if v.varValue > 0:
        print(v.name, "=", v.varValue)

# Imprimimos el resultado de la funcion objetivo (Coste total)
print(pl.value(model.objective))
print(pl.LpStatus[model.status])
return str(model)

output = execute()
file = open("Resultados.txt", "w")
file.write(output)
file.close()
```

En el código empleado, se ha desarrollado el modelado del problema de Optimización Lineal bajo la función *execute()*, para un control de la ejecución más estructurado. Mediante las tres últimas líneas de código, se consigue generar un archivo de texto con el modelo al completo, para poder analizar todo el modelo generado.

ÍNDICE DE TABLAS

Tabla 1. Etapas que seguir en la realización de un proyecto de Investigación Operativa [20].	18
Tabla 2. Costes y capacidad para cada una de las posibles localizaciones, así como la información relativa a su situación actual.	31
Tabla 3. Objetivo anual de cuota de mercado en Europa, durante los cuatro años de estrategia planteada por ECOCar Inc.	32
Tabla 4. Detalle de la distribución según ciudades para la cuota total de España planeada por ECOCar Inc.	32
Tabla 5. Coste de las diferentes entregas desde cada fábrica a cada región de demanda. Costes por cada mil unidades de envío.	33
Tabla 6. Previsiones para los próximos cuatro años -con inicio en la serie en 2021- de coches eléctricos respecto del total de matriculaciones.	43
Tabla 7. Demanda total estimada de cada uno de los países de estudio, según las consideraciones abordadas, para los próximos cuatro años.	53
Tabla 8. Demanda de vehículos esperada por ECOCar Inc. para los diferentes países a lo largo de los 4 años de estudio.	53
Tabla 9. Demanda esperada detallada de las diferentes ciudades de España según los datos del estudio.	54
Tabla 10. Demanda de vehículos eléctricos acumulados y sin redondear para fabricar por ECOCar Inc.	54
Tabla 11. Previsión anual de demanda según región, durante los cuatro años de estrategia planteada.	55
Tabla 12. Resultados obtenidos para la simulación de minimización de la función objetivo del modelo.	61
Tabla 13. Fábricas y año de compra/adquisición/uso seleccionados por el solver.	63
Tabla 14. Resultados obtenidos para la simulación de maximización de la función objetivo del modelo.	64
Tabla 15. Análisis de coste unitario y beneficios para los casos extremos resultado de la optimización.	65

Diseño de la red de la cadena de suministro de una marca de coches eléctricos para su entrada en Europa

Tabla 16. Conjunto de datos de demanda recopilados en el archivo .csv de demanda por Región y año..... 76

Tabla 17. Conjunto de datos en el archivo .csv de coste de ruta para las diferentes combinaciones desde una determinada fábrica a cada región de demanda. 77

ÍNDICE DE FIGURAS

Figura 1.1. [4] Ventas mensuales de vehículos eléctricos durante en los años 2017, 2018 y 2019, según EV Volumes [4].	7
Figura 1.2. Comparación de las ventas de coches eléctricos requeridas anualmente y la cantidad de coches eléctricos en el mercado entre 2018 y la esperada en 2030, para el panorama Europeo, según McKinsey&Company [5].	8
Figura 1.3. Matriculaciones mensuales de coches eléctricos entre 2017 y 2019, según OVEMSComillas [6].	8
Figura 1.4. Crecimiento de matriculaciones anuales totales en modelos BEV y PHEV en España, entre 2008 y 2019, según OVEMSComillas [6].	9
Figura 1.5. Crecimiento de matriculaciones por tipo de vehículo eléctrico entre 2011 y 2019, según OVEMSComillas [6].	9
Figura 1.6. Ventas globales de coches eléctricos por marcas en el año 2019, según EV Volumes [4].	10
Figura 1.7. Ventas y % crecimiento por países en 2019, según EV Volumes [4].	11
Figura 1.8. Logotipo de COIN-OR.	12
Figura 1.9. Logo de la Asociación Europea de Fabricantes de Automóviles.	12
Figura 1.10. Porcentaje del total de coches eléctricos respecto al total de vehículos vendidos en todo el mundo desde 2010 a 2017, según McKinsey&Company [8].	13
Figura 3.1. Composición y flujos en una cadena de suministro [12].	13
Figura 3.2. Logo de la librería SciPy [23].	20
Figura 3.3. Logotipo de la librería Pyomo [25].	20
Figura 3.4. Recopilación de las conductas de datos según la clasificación de Pegel [32].	22
Figura 3.5. Logotipo de la librería de Python Statsmodels.	27
Figura 3.6. Logotipo de la librería de Python Matplotlib.	27
Figura 4.1. Logotipo de la compañía ECOCar Inc.	28
Figura 4.2. Localizaciones posibles para las fábricas por el cliente -marcadas con círculos- y regiones de demanda -señaladas mediante estrellas-. Movimientos posibles, de forma simplificada, representados con flechas discontinuas. Las flechas no son representativas de las rutas empleadas, en ningún caso.	34

Diseño de la red de la cadena de suministro de una marca de coches eléctricos para su entrada en Europa

Figura 4.3. Datos mensuales de matriculación históricos para cada uno de los cinco países de estudio desde el año 1990 hasta el 2019. Fuente ACEA [32].	35
Figura 4.4. Datos de matriculación de automóviles en Francia desde el año 2015 al año 2019. Fuente ACEA [32].	36
Figura 4.5. Datos de matriculación de automóviles en Alemania desde el año 2015 al año 2019. Fuente ACEA [32].	37
Figura 4.6. Datos de matriculación de automóviles en Italia desde el año 2015 al año 2019. Fuente ACEA [32].	38
Figura 4.7. Datos de matriculación de automóviles en Holanda desde el año 2015 al año 2019. Fuente ACEA [32].	38
Figura 4.8. Datos de matriculación de automóviles en España desde el año 2015 al año 2019. Fuente ACEA.	39
Figura 4.9. Matriculaciones anuales acumuladas para cada país desde el año 2013 al 2020.	39
Figura 4.10. Matriculaciones por provincias en España para el año 2019. Fuente DGT.	40
Figura 4.11. Reajuste del porcentaje de matriculaciones según provincia a partir de los datos de 2019 de la DGT.	40
Figura 4.12. Datos de matriculaciones anuales de coches eléctricos para los diferentes países del estudio. Fuente ACEA [32].	41
Figura 4.13. Porcentaje de matriculaciones de coches eléctricos respecto del total para los últimos 5 años, según ACEA [32].	42
Figura 4.14. Previsiones para los próximos 4 años -con inicio de la serie en 2021- del porcentaje respecto del total de coches eléctricos en el total de las matriculaciones.	43
Figura 5.1. Datos históricos de matriculaciones en los últimos 5 años en los diferentes países de estudio, según los datos de ACEA [32].	49
Figura 5.2. Predicción para los próximos 5 años en Alemania a partir de los últimos 5 años históricos, empleando el método Holt-Winters.	50
Figura 5.3. Predicción para los próximos 5 años en Francia a partir de los últimos 5 años históricos, empleando el método Holt-Winters.	51
Figura 5.4. Predicción para los próximos 5 años en Holanda a partir de los últimos 5 años históricos, empleando el método Holt-Winters.	51

Figura 5.5. Predicción para los próximos 5 años en Italia a partir de los últimos 5 años históricos, empleando el método Holt-Winters.	52
Figura 5.6. Predicción para los próximos 5 años en España a partir de los últimos 5 años históricos, empleando el método Holt-Winters.	52
Figura 5.7. Coste inicial de adquisición para el comienzo de uso de las diferentes fábricas a las que tiene acceso directo o potencial ECOCar Inc.	57
Figura 5.8. Costes fundamentales asociados a la fabricación en las distintas localizaciones disponibles de ECOCar Inc. Información relativa a la Tabla 2	58
Figura 5.9. Capacidad (en miles de unidades) frente al coste asociado a la fabricación de mil unidades de vehículos (ver Tabla 2).	59
Figura 5.10. Mapa superficial de costes logísticos de recibir en una determinada región de origen respecto de una determinada fábrica (ver Tabla 4).	60
Figura 5.11. Comparación entre costes máximos y mínimos de logística para cada región de demanda.	60
Figura 5.12. Demanda cubierta frente a capacidad (en miles de unidades) para cada una de las fábricas seleccionadas, según el año.	63