



UNIVERSIDAD DE BURGOS

**Programa de Doctorado en
Ingeniería y Tecnologías Industrial, Informática y Civil**

Tesis Doctoral

**APLICACIÓN DE TÉCNICAS INTELIGENTES A
LA GESTIÓN DE LA EMPRESA INDUSTRIAL**

Autor: **Manuel Manzanedo Saiz**

Directores: **Dr. Nuño Basurto Hornillos**
Dr. Roberto Alcalde Delgado

Burgos, 2025

Agradecimientos.

Agradecimiento

A la Universidad de Burgos y al Programa de Doctorado en “Ingeniería y Tecnologías Industrial, Informática y Civil”, por ofrecerme y facilitar el ámbito investigador propicio para el desarrollo de esta investigación ingenieril.

Al Departamento de Digitalización por acogerme y darme la oportunidad de crecer en mi aprendizaje investigador dentro de sus excelentes grupos de investigación; sin la inestimable ayuda de los profesores que los conforman, me habría sido mucho más difícil realizar este trabajo.

De forma especial, como no puede ser de otra manera, a mis directores de tesis, los doctores Nuño Basurto Hornillos y Roberto Alcalde Delgado; ellos son poseedores de un gran conocimiento, alto nivel de experiencia y me han ofrecido su apoyo en todo momento. Todo esto ha sido clave en el progreso de mi formación investigadora y en la elaboración de esta Tesis.

Muchas gracias.

Resumen

El desarrollo de nuevas tecnologías como la Inteligencia Artificial permite a las empresas poder tomar mejores decisiones partiendo de datos que, una vez analizados con estas nuevas herramientas, les puede aportar información sobre distintas situaciones, previsiones futuras y nuevos escenarios, para alcanzar una mayor eficiencia en la gestión de sus recursos, así como optimizar la planificación y mejorar las operaciones. En este contexto, las técnicas de Aprendizaje Automático, también conocido como “Machine Learning”, se presentan como un importante recurso que pueden utilizar las empresas para innovar su gestión.

La integración de “Machine Learning” en la gestión empresarial, permite analizar importantes series de datos para anticiparse a nuevas situaciones en el mercado o mejorar la utilización de los recursos disponibles a fin de disminuir las ineficiencias. En esta tesis doctoral, se aplican técnicas de “Machine Learning” en dos aspectos fundamentales de la gestión de las empresas industriales y cuyos resultados han sido publicados en revistas científicas indexadas en JCR.

1. En el primer trabajo se aplican por primera vez modelos neuronales no lineales a diferentes conjuntos de datos con el fin de validar su idoneidad para predecir el precio del acero laminado en España, como materia prima clave en la industria metálica. Utilizando distintos modelos, se comparan y analizan diferentes conjuntos de datos que se constituyen en un conjunto de variables heterogéneas, durante los últimos siete años y relacionados con el precio de este metal. Los resultados obtenidos han permitido encontrar el modelo con mejor desempeño, utilizando, como entrada de modelo predictivo, el precio de las materias primas empleadas para producir acero y los precios de las bolsas de valores de tres grandes empresas productoras de acero a nivel mundial. Por tanto, los resultados de esta primera investigación pueden impulsar la aplicación de “Machine Learning” en las empresas, con el fin de programar las operaciones de suministro de acuerdo con la previsión de precios que se obtienen de su aplicación.
2. El segundo estudio se centra en el consumo energético del sector del transporte de mercancías por carretera, que representa el 40% del consumo total de energía del transporte en la Unión Europea, con el objetivo de mejorar su racionalización. La comparación entre el volumen del transporte de mercancías por carretera y el producto interior bruto indica que entre los años 2010 y 2022 descendió una media del 17,6% en la Unión Europea de los veintisiete, lo que significa que hubo un crecimiento desacoplado. De entre estos países, Alemania fue el que registró un mayor desacoplamiento, con casi el 36%, mientras que en el lado opuesto se encuentra España, en el que se detectó un acoplamiento porque la evolución de las dos variables fue casi idéntica. En la investigación se analizan los factores relevantes en la actividad del transporte de mercancías por carretera que pueden justificar las diferencias entre los países, estudiando los

impactos positivos y negativos de las distintas variables analizadas. Por último, utilizando el modelo SARIMA, se realiza una predicción sobre la evolución de indicadores relevantes del transporte por carretera en diferentes países.

Para las investigaciones desarrolladas en esta tesis, se ha realizado, previamente, un análisis del estado del arte de los resultados de la aplicación de las técnicas de Inteligencia Artificial a la toma de decisiones en gestión de empresas, no habiéndose encontrado publicaciones que hayan aplicado tales técnicas a la problemática planteada. Junto con ello, también, se han analizado las técnicas que mejor se adaptaban a los datos de partida de las investigaciones. Como consecuencia de todo este análisis, considerado como la base de esta investigación, se ha logrado la publicación de estos resultados en revistas de impacto científico.

Se debe destacar, igualmente, la eficacia de las técnicas de “Machine Learning” en la generación de información valiosa para respaldar la toma de decisiones de gestión en las empresas industriales. Puesto que analizando distintas variables que inciden en la gestión y aplicando herramientas de Inteligencia Artificial se puede generar información valiosa que ayude a respaldar la toma de decisiones y estrategias a seguir en la gestión de las empresas. En resumen, la utilización de estas técnicas, se pueden considerar como un recurso de gran ayuda, porque permiten lograr mejores niveles de competitividad en un mercado global en constante evolución en el que las decisiones a tomar deben ser cada vez más rápidas y fiables.

Abstract

The development of new technologies such as Artificial Intelligence allows companies to make better decisions based on data that, once analyzed with these new tools, can provide information on different situations, future forecasts, and new scenarios, allowing them to achieve greater efficiency in resource management, optimize planning, and improve operations. Machine Learning techniques are important resources that companies can use to innovate their management.

The integration of Machine Learning into business management allows the analysis of large data sets to anticipate new market situations or to improve the use of available resources and reduce inefficiencies. In this doctoral thesis, Machine Learning techniques are applied to two fundamental aspects of industrial company management, the results of which have been published in JCR-indexed scientific journals.

1. In the first work, nonlinear neural models are applied for the first time to different data sets to validate their suitability for predicting the price of rolled steel in Spain, a key raw material in the metal industry. Using different models,

we compared and analyzed various data sets comprising a set of heterogeneous variables from the last seven years and related to the price of this metal. The results obtained allowed us to identify the best-performing model, using the price of raw materials used to produce steel and the stock market prices of three major global steel-producing companies as inputs. Therefore, the results of this initial study can drive the application of machine learning in companies, aiming to schedule supply operations according to the price forecasts obtained from its application.

2. The second study focuses on energy consumption in the road freight transport sector, which represents 40% of total transport energy consumption in the European Union, with the aim of improving its rationalization. A comparison between road freight transport volume and gross domestic product indicates that between 2010 and 2022, the volume declined by an average of 17.6% in the European Union of 27, indicating decoupled growth. Among these countries, Germany was the country with the greatest decoupling, at nearly 36%, while Spain was at the opposite end of the spectrum. A coupling was found because the evolution of the two variables was almost identical. The research analyzes the relevant factors in road freight transport activity that may explain the differences between countries, studying the positive and negative impacts of the different variables analyzed. Finally, using the SARIMA model, a prediction is made about the evolution of relevant road transport indicators in different countries.

For the research developed for this thesis, a state-of-the-art analysis of the results of applying Artificial Intelligence techniques to decision-making in business management was previously conducted. No publications were found that have applied these techniques to the problem at hand. Furthermore, the techniques that best fit the initial research data were previously analyzed. As a result of this analysis, considered the basis of this research, these results have been published in high-impact scientific journals.

The effectiveness of Machine Learning techniques in generating valuable information to support management decision-making in industrial companies is also highlighted. By analyzing different variables that influence management and applying Artificial Intelligence tools, valuable information can be generated to help support decision-making in the management of industrial companies. In short, the use of these techniques can be considered a very useful resource, as they allow for greater levels of competitiveness in a constantly evolving global market where decisions must be made increasingly faster and more reliable.

INDICE

INTRODUCCIÓN	11
INTRODUCCIÓN	12
PARTE I: BASES Y METODOLOGÍA DE LA INVESTIGACIÓN	14
CAPÍTULO I. LA INTELIGENCIA ARTIFICIAL Y SU APLICACIÓN A LAS ORGANIZACIONES.....	15
La inteligencia artificial. Una nueva revolución emergente	15
La inteligencia artificial en la gestión empresarial. Un potencial de decisiones más acertadas y de mejores resultados	20
La inteligencia artificial en la economía globalizada. Una transformación complementaria	25
CAPÍTULO II. MÉTODOS EMPLEADOS EN LA INVESTIGACIÓN REALIZADA.....	34
Modelos autorregresivos. Modelo SARIMA	34
Modelos neuronales para la predicción de series temporales	37
PARTE II: INVESTIGACIONES REALIZADAS.....	46
CAPÍTULO III. ANÁLISIS DE SERIES TEMPORALES PARA LA PREDICCIÓN DEL PRECIO DEL ACERO LAMINADO EN CALIENTE EN ESPAÑA, MEDIANTE MODELOS NEURONALES NO LINEALES	47
CAPÍTULO IV. DIVERGENCIAS ENTRE LOS ESTADOS MIEMBROS DE LA UNIÓN EUROPEA SOBRE LA SOSTENIBILIDAD DEL TRASPORTE DE MERCANCÍAS POR CARRETERA.....	61
PARTE III: CONCLUSIONES Y LÍNEAS DE TRABAJO FUTURO.	87
CONCLUSIONES.....	88
BIBLIOGRAFÍA	93
ANEXOS: PUBLICACIONES.....	107

INTRODUCCIÓN

INTRODUCCIÓN

La tesis doctoral que se presenta ha sido elaborada dentro de las líneas de investigación seguidas en el Grupo de Investigación de Ingeniería de Organización (GIO) y en el Grupo de Investigación de Inteligencia Computacional Aplicada (GICAP) y como resultado se han logrado las dos publicaciones que se referencian a continuación:

- Manzanedo, M., Alonso de Armiño, C., Basurto, N., Alcalde, R., & Alonso, B. (2024). Divergences between EU Members on the Sustainability of Road Freight Transport. *Sustainability*, 16(15), 6268, <https://doi.org/10.3390/su16156268> (JCR, Q2, IF: 3,3) (SJR: 7,7).
- Alcalde, R., García, S., Manzanedo, M., Basurto, N., de Armiño, C. A., Urda, D., & Alonso, B. (2024). Analyzing time series to forecast hot rolled coil steel price in Spain by means of neural non-linear models. *Logic Journal of the IGPL*, jzae060, <https://doi.org/10.1093/jigpal/jzae060> (JCR, Q4, IF: 0,6) (SJR: 2,4).

Estos artículos han sido publicados en revistas científicas del ámbito de la especialidad del trabajo desarrollado en la presente tesis e indexadas en el Journal Citation Reports (JCR) (Clarivate) y CiteScore (SJR) (Scopus).

Para alcanzar estos resultados se realizó durante el año 2022, un exhaustivo estudio sobre los dos pilares que soportan las bases de los conocimientos necesarios como son la Inteligencia Artificial y su aplicación a la gestión empresarial en una economía globalizada, revisando las aportaciones más importantes hasta esa fecha. La segunda base para estas investigaciones ha sido la identificación y el análisis de las diferentes metodologías existentes para tratar los datos económicos disponibles y establecer las correspondientes predicciones.

Así, de acuerdo al planteamiento y los resultados anteriores y teniendo en cuenta la motivación y objetivos de esta tesis, el resto del documento presentado se ha estructurado como a continuación se indica:

- **Parte I.** La Inteligencia Artificial y su aplicación a las organizaciones: En el capítulo primero se reflejan los conocimientos previos adquiridos para poder realizar las investigaciones. Se parte de la consideración de la Inteligencia Artificial como una revolución emergente que puede aplicarse a la toma de decisiones, al objeto de poder realizar una mejor gestión empresarial, dentro de la transformación necesaria para competir de manera más eficiente en una la economía global. En el capítulo segundo se explican, con mayor amplitud, las metodologías aplicadas a los datos de partida para cada una de las dos investigaciones realizadas.

- **Parte II.** Investigaciones realizadas: Esta segunda parte presenta los artículos desarrollados por el autor y directores de la tesis y publicados en revistas científicas del ámbito de estudio, citados anteriormente.
- **Parte III.** Discusión y Conclusiones: Corresponde al análisis de los resultados de los artículos seleccionados, presentando, además las conclusiones y su discusión, así como algunas propuestas de interés para el trabajo futuro de esta línea de investigación.

PARTE I: BASES Y METODOLOGÍA DE LA INVESTIGACIÓN

CAPÍTULO I. LA INTELIGENCIA ARTIFICIAL Y SU APLICACIÓN A LAS ORGANIZACIONES

La Inteligencia Artificial. Una nueva revolución emergente

La Inteligencia Artificial (IA) ha surgido como una tecnología dentro del campo de las ciencias de la computación, para resolver más eficientemente algunos de los problemas empresariales asociados comúnmente a la inteligencia humana, y con el objetivo de que la empresa tome decisiones mejores y más fiables en casi todos sus ámbitos de actuación. Según Tambe et al. (2019), es una categoría amplia de tecnologías que permite a una máquina realizar tareas que normalmente, hasta ahora, necesitaban de la cognición humana.

Actualmente, la mayoría de las organizaciones disponen de una enorme cantidad de datos e información que se originan en las diferentes fuentes vinculadas con su actividad empresarial, y que se pueden almacenar en bases de datos de gran tamaño. A estos datos se les aplica las correspondientes tecnologías, para que aporten información y conocimiento que ayuden a tomar mejores y más rápidas decisiones empresariales.

Así es como ha nacido una tecnología transformadora que intenta revolucionar los procesos de toma de decisiones en el ámbito organizativo (Russell & Norvig, 2016). Para ello, utiliza el aprendizaje automático y redes neuronales en el estudio e investigación de tal cantidad de datos, detectando patrones y generando información para una toma de decisiones eficaz y rentable.

La utilización de esta tecnología en la toma de decisiones aporta imprescindibles beneficios, como una mayor precisión en los análisis de predicciones (Brynjolfsson & McAfee, 2014), integrando sus aplicaciones para optimizar las soluciones a aplicar no sólo a los problemas sociales, sino también a los procesos empresariales, permitiendo mejorar los servicios y productos desarrollados y generar nuevos conocimientos.

Muchos investigadores sitúan el origen de la IA en el año 1950 con la publicación de Turing (1950), en la que se cuestionó si las máquinas podían pensar y su conocida “prueba de Turing” (evaluar la capacidad de una máquina para mostrar un comportamiento inteligente similar al de los humanos). En este artículo, el citado autor propuso, por primera vez, este término o denominación y lo presentó como un

concepto relativamente filosófico y teórico. Posteriormente, McCarthy et al. (1955) la definieron como la ciencia y la ingeniería para fabricar máquinas inteligentes.

Durante las dos siguientes décadas, el desarrollo de nuevas investigaciones en computación, consiguieron novedosas máquinas que podían almacenar mayor número de datos y, además, con un procesamiento más rápido. Paralelamente, se comenzó, también, con el desarrollo de más algoritmos, creándose, de este modo, un fondo para la investigación de la IA; aunque el objetivo inicial era descubrir si los nuevos ordenadores podían transcribir el lenguaje hablado.

A partir de 1980 se dispuso de una mayor financiación para la investigación en este interesante campo de estudio, lo que permitió el desarrollo de nuevas herramientas algorítmicas que los investigadores utilizaron para avanzar en su estudio y en la optimización de su desarrollo. Entre otros, destacamos los trabajos de Hopfield (1982, 1984), Hopfield & Tank (1985) y Rumelhart & Zipser (1985), que trataron sobre técnicas de aprendizaje profundo, demostrando que los ordenadores podían aprender de la experiencia.

En las dos décadas posteriores se siguió avanzando en esta ciencia y uno de los logros de mayor impacto comunicativo socialmente fue la victoria, en 1996, de la IA al entonces campeón mundial de ajedrez, Garry Kasparov. En realidad, del encuentro programado al mejor de seis partidas, la tecnología ganó la primera; G. Kasparov, tres partidas y las dos restantes quedaron en tablas. Se puede interpretar que fue la primera vez que la máquina, desarrollada por IBM (de nombre "Deep Blue"), venció al cerebro humano o, también, la primera vez que la inteligencia humana derrotó a una tecnología diseñada para vencerla.

A medida que se contaba con más datos de computación y una mayor potencia de procesamiento, en la anterior década de este siglo se ha avanzado con mayor rapidez en su estudio e investigación, haciéndola cada vez más accesible en casi todos los ámbitos sociales y observando, en los últimos años, una evolución muy rápida. Todo esto con base en los nuevos desarrollos del software que consiguen abordar y concluir operaciones cada vez más difíciles e incluso imposibles para la mente humana, tanto a nivel personal como empresarial, y de la sociedad en su conjunto.

Para poder lograr el objetivo mencionado, la IA integra distintas tecnologías como el aprendizaje automático, el procesamiento del lenguaje natural y las redes neuronales artificiales (Ciulli & Kolk, 2023; Soori et al., 2023a).

Actualmente, ofrece una serie de desarrollos que la sociedad puede aplicar para obtener una mayor eficiencia en el uso de los recursos disponibles en casi cualquier ámbito socio-económico, como, por ejemplo:

- La resolución de problemas complejos utilizando el aprendizaje automático.

- La mejora de la eficiencia empresarial mediante la sustitución de las tareas manuales.
- La automatización de procesos empresariales mediante el entrenamiento de modelos para realizar tareas de forma más rápida y precisa.
- La toma de decisiones más acertada mediante el uso y análisis de ingentes cantidades de datos de forma más rápida que los humanos.

Por todo lo anterior, puede ser considerada como un sistema informático que realiza sus operaciones como los seres humanos, imitando así al intelecto humano (Fleck, 2021; Prentice et al., 2020).

Así, avanzando en la comprensión de la IA, las redes neuronales artificiales (*Artificial Neural Networks, ANN*) y el Aprendizaje Profundo (*Deep Learning, DL*) (entendido como una rama de la IA que aprende de los datos usando las redes neuronales artificiales) se pueden considerar componentes del Aprendizaje Automático (*Machine Learning, ML*) (comprender la información y adquirir cada vez más experiencia, en vez de programarlo explícitamente para ello) y, éste a su vez, como un subconjunto de la tecnología que se investiga en este trabajo, como se refleja en la Figura 1. Por tanto, el DL no deja de ser un ML, a modo de entrenador de ordenador, para ejecutar y reiterar operaciones, trabajos, análisis, etc. como los que ejecutan las personas, siendo imprescindible para la IA. Con estas técnicas de aprendizaje se consiguen múltiples capacidades de gran importancia, como catalogar, reconocer, caracterizar, detectar o especificar datos e información (Álvarez, 2022).




Figura 1.- Tecnologías de la Inteligencia Artificial. Fuente: Elaboración propia.

Todas estas tecnologías, correctamente estructuradas, ordenadas y bien aplicadas, pueden, como se ha comentado, ayudar a resolver problemas y desafíos sociales de gran envergadura, incluidos el cambio climático, la pobreza o la seguridad alimentaria (Ciulli & Kolk, 2023).

Dado que en nuestras investigaciones utilizamos, fundamentalmente, la tecnología ML, en el presente trabajo se considera como una familia de la IA que consigue interpretar los datos y mejorar con la experiencia. Su propósito principal es conseguir las técnicas y métodos más adecuados para que el software aprenda y se perfeccione sin programarlo explícitamente. Los modelos o programas resultantes deben ser capaces de generalizar comportamientos e inferencias para un conjunto más amplio (potencialmente infinito) de datos e información (Álvarez, 2022).

Para esta investigación, conviene apuntar, que el ML utiliza distintos tipos de modelos de aprendizaje y diferentes técnicas algorítmicas. Así, atendiendo a la variedad de los datos utilizados y los resultados que se esperan obtener se pueden utilizar los siguientes paradigmas: supervisado, no supervisado, semi-supervisado o de refuerzo. En cada uno de ellos se aplican técnicas algorítmicas variadas para tomar decisiones, proyectar resultados o encontrar patrones y correlaciones. Por ello, las empresas que utilizan el ML pueden analizar casi cualquier impacto operativo en áreas como el marketing, los ERPs y la automatización de procesos o el mantenimiento predictivo.

A veces, cuando en el algoritmo utilizado no se llega a saber lo que ocurre y, además, los resultados son muy complejos, se denomina modelos de “caja negra”. Esto puede poner en riesgo a las empresas si son incapaces de conocer porqué el algoritmo propone una determinada solución. Pero las investigaciones avanzan cada vez más rápido y a medida que aumenta la complejidad, también se crean nuevas herramientas y se desarrollan más recursos para gestionar los riesgos y sesgos, creando y actualizando nuevos elementos de control y protocolos dentro de esta nueva tecnología.

El espectacular desarrollo de la IA ha permitido obtener una importante serie de aplicaciones prácticas, cuyo listado es bastante amplio, y del que destacamos: a) el reconocimiento de imágenes y voz (esto sirve por ejemplo, en los sectores de la seguridad, educación o salud); b) el aprendizaje automático, que consiste en instruirse y adquirir conocimiento de los datos “sin ser explícitamente programado para ello”, muy útil en medicina, ciencia o finanzas ; o c) la robótica, desarrollando robots más independientes, autónomos y fiables, un ejemplo son los robots desarrollados por la empresa Boston Dynamics para sustituir a las personas en escenarios peligrosos, repetitivos y difíciles¹.

¹ Boston Dynamics - (<https://bostondynamics.com/about/>)

Estamos hablando de procesamiento inteligente de datos y documentos, aprendizaje, higiene y seguridad laboral, mantenimiento predictivo o análisis empresarial. Para ello, se utilizan la visión artificial, el reconocimiento de la voz, el procesamiento del lenguaje o la inteligencia artificial generativa. Así, el procesamiento del lenguaje natural permite a los sistemas comprender el lenguaje humano complejo, entender contextos matizados e interpretar significados variados (Jarrahi, 2018). La traducción de idiomas basada en inteligencia artificial, por ejemplo, que utiliza el procesamiento del lenguaje natural, puede mejorar la comunicación al ofrecer traducción simultánea en tiempo real, superando las barreras del idioma a las personas y fomentando organizaciones más fuertes y efectivas (Elhadi, 2023).

Su ámbito de actuación requiere diferentes capacidades como percepción, razonamiento, aprendizaje y toma de decisiones, a nivel individual e institucional (Manning, 2020; Xie & He, 2022). Pero, también, se enfrenta a distintos desafíos, riesgos e incluso dilemas éticos, centrados, por ejemplo, en desigualdades, mal uso o pérdidas de empleo, que pueden dificultar su rápido avance. Entre ellas aparecen las nuevas y cada vez mayores restricciones regulatorias y normativas de privacidad; la necesidad de gran potencia de procesamiento para que funcionen las tecnologías de aprendizaje profundo; o la imprescindible disponibilidad de capacidad de almacenamiento para procesar y gestionar los datos necesarios para el entrenamiento.

Sobre las políticas, prácticas y normativas que sirvan para reducir los riesgos y garantizar un uso responsable para beneficio de todos, la UE ya ha acordado las primeras leyes para regular de manera formal la IA, convirtiéndose en el primer continente que lo hace. Se firmaron en diciembre de 2023 y empezarán a regir a finales de 2026, aunque algunas normativas se iniciarán antes; no obstante, significa un principio importante de regulación de esta tecnología. Es importante resaltar que esta normativa europea se ha redactado teniendo en cuenta el riesgo que puede generar para las personas y, en consecuencia, permite o prohíbe su uso, teniendo como objetivo primordial que sea segura y respete los derechos fundamentales y los valores europeos.

Así, las redes neuronales artificiales son tecnologías basadas en determinados paradigmas que simulan la estructura del cerebro humano y constan de múltiples neuronas interconectadas en las que se almacena la información (Soori et al., 2023b). La mayor parte de esta información se guarda en capas ocultas de neuronas, que residen entre la capa de entrada y la capa de salida (Sang, 2021). En la fase de entrenamiento, las redes neuronales artificiales se alimentan de datos (Stair et al., 2021). Una vez que las redes neuronales artificiales hayan sido suficientemente entrenadas, se podrán emplear en nuevos escenarios y, en consecuencia, calcular el resultado para cada uno de ellos (Stair et al., 2021).

Sobre los modelos basados en agentes que se identifican con modelos computacionales sustentados en un esquema, se puede considerar como un ordenamiento de actuación que trata de seguir unas reglas de decisión simples (Massari & Giannoccaro, 2021). Tales reglas simulan las interacciones de entidades individuales, llamadas agentes, a lo largo de un proceso de decisión, actuando de forma autónoma (Toorajipour, 2021).

Dentro del DL, las ANN son las que conforman el sustento y base tecnológica de la IA, ya que se asemejan al proceso que ocurre en el cerebro humano, donde existen millones de neuronas que actúan juntas para procesar y analizar datos e información. Por ello, los modelos con neuronas artificiales son muy competentes y han tenido una gran acogida por la comunidad científica, tecnológica y empresarial, puesto que sirven muy bien para adelantar hoy lo que puede pasar en el futuro con un grado de acierto alto (Jumper, 2021).

La IA está modificando las empresas y el mundo a una velocidad enorme y el impacto en las personas, organizaciones y sociedad es incuestionable (puestos de trabajo, hogares, teléfonos inteligentes, relaciones, vehículos, etc.). Y no solo esto, sino que cada vez es más omnipresente, porque los modelos y algoritmos que utiliza sirven para hacer tareas que hasta hace poco no podían realizar las máquinas (juegos de estrategia, traducir idiomas, producir contenido creativo, etc.).

Además de ser más influyente, también es más cercana y asequible, pudiendo abarcar una gran variedad de problemas, de naturaleza distinta, desde los del sector sanitario hasta los derivados de las empresas de producción y comercialización, por citar algunos. Es más omnipresente, más cercana y está más incorporada en la vida habitual y cotidiana. Se manifiesta, por ejemplo, en los asistentes virtuales, los coches autónomos, etc.; ello significa que afecta al modo y manera que tenemos de vivir y trabajar. Y cada vez su impacto y utilidad será mayor.

La inteligencia artificial en la gestión empresarial. Un potencial de decisiones más acertadas y de mejores resultados

En la gestión empresarial, existe la necesidad, cada vez mayor, de una toma de decisiones rápida, acertada y precisa, de tal forma que en las últimas décadas se ha avanzado en la definición e implantación de nuevos sistemas y técnicas de información, los cuales han afectado rápidamente la toma de decisiones tradicional (Yang et al., 2019; Taleizadeh et al., 2018). Estos sistemas, con el tiempo, han ido evolucionando desde los basados en máquinas, hasta aquéllos capaces de adquirir datos, adaptarse y organizarse a un entorno cambiante y dinámico (Keith & Ahner, 2019). Actualmente, tales sistemas son de una mayor complejidad debido a su

exposición a la nube, otras plataformas de Internet y amplias herramientas de generación de datos (Botta et al., 2016; Hashem et al., 2015).

La tercera revolución industrial tuvo que ver con la digitalización y muchas empresas, desde las de servicios logísticos y financieros hasta las de mercados electrónicos, han integrado la investigación operativa en sus operaciones comerciales para responder agresivamente a las necesidades de sus clientes (Crainic, 2009). Pero con la llegada de la digitalización, las compañías comenzaron a generar una enorme cantidad de datos a una velocidad aún mayor, por lo que resultó necesario aprovecharlos para una mejor toma de decisiones (Bhimani & Willcocks, 2014).

En las investigaciones anteriormente citadas, se puede observar el estudio separado de la IA, la investigación de operaciones y los sistemas de apoyo a la dirección, o a lo sumo, el estudio combinado de dos de ellas (Duan et al., 2019; Perraju, 2013), observando que el análisis conjunto de las dos primeras no se ha estudiado en detalle. Aunque investigadores como Karacapilidis & Pappis (1997) ya desarrollaron un marco inicial para emplear herramientas de IA, investigación de operaciones y sistemas de apoyo a las decisiones, con el objetivo de ser utilizadas conjuntamente.

Por ello, mediante la recientemente acuñada como “cuarta revolución industrial” o también “industria 4.0”, con tecnologías como la IA, se está entrando en el ámbito físico y digital para avanzar en los procesos de toma de decisiones y en nuevas formas de gestionar las empresas (Hamet & Tremblay, 2017). Es de destacar que las posibilidades que tiene esta nueva tecnología para crear escenarios y decisiones de gestión reales y cuasi reales le hacen más apropiada para que las empresas la apliquen como una innovación disruptiva (Wright & Schultz, 2018). Así, el desarrollo de esta cuarta revolución industrial, está ayudando a transformar la producción, las operaciones, la logística y toda la gestión de las empresas, por lo que debe integrarse en la toma de decisiones empresariales.

Por tanto, la IA comenzó proporcionando autonomía y flexibilidad a los sistemas de apoyo a la dirección en un entorno como el actual, considerado turbulento, incierto y dinámico (Kobbacy & Vadera, 2011), y para ello se comenzó utilizando modelos de redes neuronales para el proceso de toma de decisiones (Svozil et al., 1997). Así, en los inicios de este siglo, con los nuevos desarrollos informáticos y las mejoras en el aprendizaje automático y el Big Data, se avanzó en una nueva e interesante orientación en la investigación de la IA (Wamba, 2017).

Las empresas industriales necesitan herramientas y apoyo para poder tomar las mejores decisiones con las que realizar eficientemente las operaciones, como el diseño de productos y procesos, la programación de líneas de producción y equipos industriales para una utilización óptima, la gestión de la calidad, el mantenimiento

eficiente, la identificación de fallos y cualquier otra actividad de la cadena de suministro (Laguna-Salvadó et al., 2019; Mar-Ortiz et al., 2019; Scott et al., 2015).

Para ello, los sistemas de apoyo a las decisiones, ayudan a determinar y decidir el curso de acción para realizar las tareas directivas. Estos sistemas pueden tratar cantidades ingentes de datos y contribuir con actividades clave de toma de decisiones (Aboytes-Ojeda et al., 2019), siendo capaces de capturar, almacenar y recuperar datos con un mecanismo de control de retroalimentación (Singh et al., 2018). En cada empresa, su diseño depende de las estrategias adoptadas (Kirlar et al., 2018), para que puedan ser competentes para resolver problemas y tomar decisiones de gestión en un contexto turbulento y de incertidumbre (Keith & Ahner, 2019).

En el desarrollo de los sistemas de apoyo a la dirección se pueden utilizar conocimientos de lógica difusa, algoritmos genéticos, sistemas basados en agentes o redes neuronales (Kobbacy & Vadera, 2011; Min, 2010). Analizando su posible aplicación, se observa que los sistemas basados en agentes son útiles en la planificación y previsión de la demanda, la gestión de las relaciones con los clientes, el cumplimiento de pedidos o la negociación con proveedores y otros socios de la cadena de valor (Monteserin & Amandi, 2011; Efendigil et al., 2009). Los algoritmos genéticos pueden resultar útiles en el diseño de la red (Kin, 2000). Además, los sistemas expertos ayudan a la planificación de inventarios, decisiones de fabricación o compra y actividades relacionadas con la selección de proveedores (Moslemi & Zandieh, 2011; Cebeci, 2009).

Hoy en día, las empresas necesitan estas tecnologías para desarrollar todos los procesos de sus productos y servicios; así, ha sido posible, por ejemplo, diseñar automóviles sin conductor con la capacidad de aprender e identificar patrones (Chan, 2017), por lo que se ha ido adquiriendo la suficiencia para cuantificar la incertidumbre y anticipar las necesidades de datos de los usuarios. También, poseen un importante poder predictivo y de razonamiento para la planificación y manipulación de objetos (Tang et al., 2018; Gayathri & Uma, 2018), así como para la identificación de herramientas óptimas y parámetros de corte que permiten mejorar significativamente las operaciones de fresado y torneado (Saranya et al., 2018).

El enorme aumento de la complejidad y el flujo de datos en los últimos años, ha puesto sobre la mesa la necesidad de definir una plataforma de toma de decisiones que sea óptima, lógica y rápida (Duan et al., 2019). Por tanto, en este entorno incierto donde la información está disponible en diferentes formas (imágenes, texto y números), se necesitan tecnologías que no sólo generen nuevos datos, sino que también tengan la capacidad de aprender continuamente del entorno y desde distintos escenarios, para recomendar decisiones (Baryannis et al., 2019). En distintas empresas, aún en estos momentos, algunos directivos toman sus decisiones basándose en el análisis tradicional y en su vieja experiencia, por lo que los resultados pueden ser menos

rápidos y precisos (Iansiti & Lakhani, 2020). En un estudio de los autores anteriormente citados, se comprobó que, combinando la investigación de operaciones, los sistemas de apoyo a la dirección los programas de sistemas de análisis (SAP) y la IA, ayudaba a gestionar las empresas de una manera mucho más eficaz.

Así, las nuevas tecnologías resultan fundamentales en la toma de decisiones sobre investigación de operaciones y utilizan la búsqueda avanzada para tomar decisiones basadas en negocios, informática y matemáticas (Nedèlková et al, 2018; Cheng & Janiak, 2000). El objetivo principal de la investigación operativa es la optimización, y este objetivo se puede lograr mediante la automatización, es decir, la casi ausencia de intervención humana, en las decisiones (Askarzadeh & Rezazadeh, 2013). Antes, los sistemas tradicionales de apoyo a la toma de decisiones solo permitían tomar decisiones mediante el modelado de datos y los cálculos numéricos, sin embargo, incluyendo las nuevas tecnologías el mecanismo decisional en la empresa cambia porque combina análisis cualitativos y cuantitativos; ya que como se indicó en el anterior epígrafe, el sistema simula una inteligencia cercana a la humana.

Se han realizado estudios con software específico de IA en los sistemas de apoyo a las decisiones; como el diseño de un buque (Chou & Benjamin, 1992) y el desarrollo de su sistema de eficiencia energética, (Beşikçi et al., 2016) el avance y progreso de las cadenas de suministro (Sahebjamnia et al., 2017); la teledetección (Kouziokas & Perakis, 2017) o el apoyo a las decisiones clínicas (Suzuki & Chen, 2018). Todos estos estudios utilizaron distintas capacidades contenidas en las nuevas tecnologías, pero hoy nos quedan algunas dudas sobre si el tipo de capacidades empleadas han sido las adecuadas para respaldar la toma de decisiones en diferentes escenarios.

Además, las investigaciones enfatizan en el enfoque diagnóstico de la toma de decisiones (Bera, 2019), ya que no consideran la incertidumbre del entorno. Por lo tanto, en la actual situación turbulenta e incierta, parece más apropiado utilizar las capacidades de toma de decisiones de pronóstico que posee la IA. Programas como Google DeepMind² y AlphaGo³) constituyen un buen ejemplo de ello, generado confianza para investigar el creciente papel de la tecnología más novedosa y los sistemas de apoyo a la dirección (Lui & Lamb, 2018; Kaplan & Haenlein, 2018) y, también, para su aplicación en la industria y en los servicios (de Sousa Jabbour et al., 2018).

Recientemente, Balbaa & Abdurashidova (2024) han analizado las ventajas que tiene la IA en la toma de decisiones y, tomando como base la eficiencia, la precisión, los datos y las tareas, organizan los beneficios en cuatro grupos homogéneos.

² DeepMind - (<https://deepmind.google/about/>)

³ Alpha Go – (<https://deepmind.google/technologies/alphago/>)

Así, consideran como primera ventaja clave, el potencial de una mayor eficiencia y velocidad, ya que de acuerdo con Brynjolfsson & McAfee (2014), puede mejorar la automatización de la toma de decisiones, reduciendo el tiempo y el esfuerzo necesarios en el análisis manual. La tecnología moderna permite procesar rápidamente grandes cantidades de datos, aprovechando el poder computacional y los algoritmos avanzados y generar conocimientos a un ritmo mayor que el cerebro humano.

Una segunda ventaja es el aumento de precisión y coherencia en las decisiones empresariales. Tales sistemas, según Srinivasani (2018), consiguen analizar datos de manera objetiva, para tratar de minimizar la influencia de los sesgos y juicios humanos subjetivos. Además, los algoritmos logran aplicar reglas predefinidas o patrones aprendidos, asegurando resultados de decisión consistentes. Como indica Chowdhury et al. (2023), la IA intenta mitigar el sesgo eliminando criterios subjetivos, ya que la posible amplificación de la tendencia surge de los sistemas entrenados en conjuntos sesgados.

Otra de las ventajas es el manejo de conjuntos de datos grandes y complejos, que pueden ser muy difíciles de analizar para los humanos. En este caso, la minería de datos o el reconocimiento de patrones, consiguen extraer información valiosa de grandes cantidades de datos (Hastie, 2009). Esta capacidad permite a los tomadores de decisiones proponer patrones, tendencias y vínculos, que estaban ocultos, contribuyendo a decisiones mejores y más certeras.

También ofrecen ventajas en los procesos de automatización de tareas repetitivas involucradas en la toma de decisiones, permitiendo liberar recursos humanos para actividades más complejas y estratégicas. Al automatizar tareas rutinarias y sencillas, los sistemas actuales pueden reducir la probabilidad de errores y permitir que los empleados se concentren en tareas de mayor valor que requieren creatividad y pensamiento crítico (Bughin et al., 2018).

Un ejemplo interesante y de gran repercusión mediática es el robot “Mika”, creado con IA para ser CEO de la compañía polaca Dictador⁴, dedicada a la venta de ron, café y otras bebidas espirituosas. Mika incluso ha firmado su correspondiente contrato con la empresa y ejerce como miembro de la Junta Directiva. Esta CEO asegura que es mucho más eficiente que los humanos, porque está pensando continuamente, disponible todas las horas del día, sin descanso, lista para tomar decisiones ejecutivas. Se dedica a un gran número de tareas y las decisiones que toma se justifican en un amplio análisis de datos y en la confluencia con los objetivos estratégicos de la empresa. Garantiza

⁴ Mika - (<https://www.dictador.com/>)

decisiones imparciales y estrategias alineadas con los mejores intereses de la empresa⁵.

En este tipo de simulaciones o técnicas de optimización de investigación de operaciones y en los sistemas de apoyo a la dirección, aunque se ha realizado una gran investigación, lo interesante es que continuamente proporciona nuevas ramas en las que profundizar y estudiar. A este respecto, se observan algunas lagunas en las publicaciones actuales, en cuanto a capacidades, incertidumbre y eficiencia de las técnicas utilizadas (Gupta et al., 2022). Teniendo en cuenta estas lagunas, en el Estado del Arte de esta investigación, se pretende aportar, con nuestro estudio, dedicación y reflexión, parte del conocimiento necesario para que la IA ayude y mejore las organizaciones, ya sean empresas u otras.

La inteligencia artificial en la economía globalizada. Una transformación complementaria

La IA puede considerarse, actualmente, el elemento motor que está recomponiendo los negocios en la economía global. Así, en la era de la llamada “revolución digital”, los programas, instrucciones, datos, etc. de naturaleza tecnológica se han convertido en herramientas imprescindibles para alcanzar la eficiencia empresarial, así como la necesaria innovación que se requiere para avanzar y progresar a nivel mundial. En los epígrafes anteriores se han revisado las diversas tecnologías asociadas, que pueden ser fundamentales para abordar los complejos desafíos asociados con las operaciones globales.

Por ejemplo, el ML se ha utilizado para mejorar la comprensión de la heterogeneidad cultural dentro de un país (Messner, 2022) o el procesamiento del lenguaje natural; lo que ha provocado incluso huelgas de guionistas en Hollywood, que temían ser sustituidos por las nuevas tecnologías (Alvarez-Mitchell, 2023). En todo caso, la aplicación de la IA, debe tener un objetivo muy claro, que es beneficiar a todos los seres humanos.

Su utilización en la economía globalizada es fundamental para acrecentar procesos, procedimientos y toma de decisiones, especialmente en el contexto de las empresas que operan en entornos globales (Bag et al., 2021) y complejos, al facilitar el análisis predictivo avanzado y aprovechar la información basada en datos (Allal-Chérif et al., 2021).

⁵ Mika Noticia - (<https://computerhoy.com/tecnologia/mika-primer-ceo-robot-inteligencia-artificial-compania-dictador-1282992>)

La aceptación intencionada y rigurosa de esta tecnología en la actividad habitual de la empresa puede generar importantes beneficios. Se prevé que habrá 13 billones de dólares adicionales en la actividad económica mundial para 2030, como resultado del uso de la IA, según un informe de McKinsey (Bughin et al., 2018). Por ello, las empresas multinacionales se plantean un mayor uso de esta como estrategia corporativa, ya que pueden estar en una mejor posición para predecir las demandas del mercado, minimizar los riesgos, optimizar la gestión de la cadena de suministro y mejorar las transacciones internacionales (Li et al., 2021; Shi, 2022).

Se trata de una revolución destinada a mejorar la productividad y aumentar el crecimiento mundial, generar más ingresos y menos costes, conseguir empresas de todos los sectores más prósperas, identificar nuevos nichos de actividad o favorecer el trabajo, la vida y la economía, pero sin crear desigualdades entre los países y personas, sino contribuyendo a una mayor igualdad entre los mismos.

Se ha planteado abiertamente durante el pasado año 2023, el debate sobre la IA por la introducción y el fácil acceso a tecnologías como Chat-GPT y otros programas similares, ya sea el Copilot de Microsoft o Gemini de Google. Ello ha generado una curiosidad sobre su impacto en el panorama laboral y empresarial, observándose una brecha sustancial de conocimiento sobre su aplicación en diversas facetas de las estrategias y las actividades de gestión. Así como en los países desarrollados y emergentes o entre las personas que saben o no manejarla.

También a nivel académico ha crecido el debate sobre la investigación de los diferentes tipos de herramientas y técnicas digitales y su utilización en las entidades para que logren avanzar en innovación y competitividad (Castellacci & Viñas-Bardolet, 2019). Para ello, se han asignado nuevas convocatorias de becas académicas sobre IA aplicada a la gestión internacional de empresas, habiendo recibido también una importante atención en las principales revistas científicas (Malik et al., 2023). Sin duda, es clave en la investigación académica descubrir y aprovechar los hallazgos existentes, para poder orientar las investigaciones y reconocer áreas inexploradas que requieren más estudio (Paul, 2021; Menzies et al., 2024).

Algunos autores, como Jones (2023), indican que queda un importante camino por recorrer entre las investigaciones y su aplicación a través de las correspondientes tecnologías relacionadas, para proporcionar soluciones de gestión efectivas a todas las áreas funcionales y su vinculación con otras operaciones empresariales. En este sentido, Menzies et al. (2024) analizan las aplicaciones de estas novedosas tecnologías a la administración y organización de las empresas internacionales. Siguiendo este esquema de trabajo se plantea su análisis en la dirección estratégica de las empresas globales. Así, los campos de aplicación se pueden ordenar en cuatro grupos: el comercio internacional, las operaciones y la cadena de suministro en el mercado

global, la innovación y la sostenibilidad, y, por último, el capital humano y la gestión de las distintas culturas asociadas al mismo.

Sobre el comercio internacional, las estrategias y complejidades tecnológicas han influido en gran medida en las decisiones empresariales para su entrada en los mercados internacionales (Benito et al., 2022) y, por tanto, en la economía globalizada. La posibilidad de compartir información a nivel global que proporciona la tecnología, impulsa compromisos empresariales mucho más globales a un menor coste (Stallkamp & Schotter, 2021), puesto que puede ser una ayuda eficaz en la selección de criterios para la localización y posicionamiento en mercados internacionales y conocer las oportunidades emergentes en el mercado global (Luo & Zahra, 2023).

Las herramientas de IA generativa comentadas anteriormente permiten generar rápidamente planes de negocio integrales (Hughes, 2023) y, también, crear perfiles de países, industrias, puestos de trabajo y competidores. Las aplicaciones de ML pueden identificar subgrupos culturales y de mercado, en lugar de sólo las naciones adecuadas (Messner, 2022). También, los algoritmos pueden ayudar a predecir las posibilidades que ofrece el mercado internacional para las nuevas empresas globales, que, mediante pronósticos más precisos, mejoran la selección de mercado y la posibilidad de participar en la expansión del mercado en el futuro (Neubert, 2018).

También puede utilizarse para mejorar los resultados de las negociaciones comerciales internacionales (O.C.D.E., 2022), a través del análisis de las trayectorias económicas de diferentes negociadores, de los resultados de la negociación comercial y de los variados requisitos de los países según sus distintas formas de liberalización comercial.

El segundo grupo de aplicación se refiere a las operaciones y la cadena de suministro en el mercado global. En los anteriores epígrafes se hacía referencia a las redes neuronales, los sistemas basados en agentes y los algoritmos genéticos, como las tecnologías más utilizadas en la gestión de las operaciones necesarias para que el producto llegue al cliente final. Pues bien, las redes neuronales, por ejemplo, proporcionan una importante ayuda en múltiples aspectos empresariales de gran importancia vinculados con la previsión de la demanda, la planificación y programación de la producción y optimización de los inventarios, la planificación logística y de rutas, la valoración y control de posicionamiento de proveedores, la calidad, los tiempos de entrega, precios y riesgos (Soori et al., 2023b). Autores como Zhu & Liu (2022), analizaron en su estudio la eficacia de las redes neuronales artificiales en la evaluación de riesgos, estableciendo un sistema de indicadores de los factores de riesgo, llegando a predecir el riesgo en la cadena de suministro con una precisión del 96% al 100%.

En los sistemas basados en agentes, estos agentes pueden actuar como proveedores, fabricantes, distribuidores y minoristas, lo que permite que el sistema capture las complejidades y el comportamiento emergente de la cadena de suministro y consiga

que los decisores permitan identificar posibles cuellos de botella, predecir las variaciones tanto de la oferta como de la demanda, y diseñar cadenas de suministro más resilientes y eficientes (Massari & Giannoccaro, 2021). Distintos autores, como Blos et al. (2018), han desarrollado sistemas para la gestión de interrupciones en la cadena de suministro. La utilización de estos sistemas logra simular y optimizar interacciones complejas entre distintos elementos, llegando a fortalecer y adaptar las cadenas de suministro internacionales para alcanzar mayor resiliencia y adaptabilidad.

Respecto a las operaciones, las nuevas tecnologías asociadas, generan mejores oportunidades en los procesos productivos y pueden ayudar a aumentar los indicadores de eficiencia en la producción, además de reducir costos y, por tanto, añadir valor a los clientes (Beltrami et al., 2021). Los procesos de producción inteligentes logran utilizar datos en tiempo real para funcionar de forma autónoma y flexible y, así, poder adaptarse con facilidad a distintos escenarios, mediante la gestión de diferentes alternativas de producción, fabricación de diversas cantidades por referencia de producto o el uso de las tecnologías de fabricación más adecuadas (Ancarani et al., 2019).

Los datos son clave para una mayor y mejor automatización de los procesos productivos globales, por la agilidad e información procesable que se obtiene a través de los distintos sensores ubicados en las máquinas y que, utilizando distintas tecnologías inteligentes, han impulsado la transformación digital en la economía global. Algunos investigadores sostienen que los ecosistemas de operaciones globales se conectan digitalmente, lo que permite que la codificación y la tecnología ejecuten algoritmos y encuentren patrones de actuación más ventajosos (Luo & Zahra, 2023).

Autores como Meltzer (2018) y Dachs et al. (2019) apuntan que la IA también podría utilizarse para mejorar la relocalización de la producción, dado que la automatización y la impresión 3D permiten reducir la necesidad de cadenas de suministro globales que dependan de mano de obra de bajo coste; pero también, una mayor automatización de la producción podría respaldar ésta en países desarrollados y avanzados. Por lo tanto, puede ayudar a identificar dónde, cuándo y qué recursos globales deberían desplegarse, ayudando a las empresas multinacionales a reconfigurar, maniobrar y reutilizar los recursos y capacidades existentes para operaciones globales.

En el tercer grupo dedicado a la innovación y la sostenibilidad, además de impulsar la eficiencia, se puede estimular la innovación y catalizar la sostenibilidad del negocio en los mercados globalizados. Según la OCDE (2022), la IA tiene la posibilidad de generar y aumentar la innovación, así como la agilidad operativa y la toma de decisiones estratégicas, creando valor a partir de los datos y así, generar una ventaja competitiva en un mercado globalmente integrado y de ritmo acelerado. Además, permite aumentar la creatividad humana, facilitando el desarrollo de nuevos productos, procesos y servicios, a través de modelos de negocio más innovadores (Haan & Watts,

2023). Con una visión más innovadora, ofrece mejores oportunidades para que las empresas multinacionales consigan mayor eficiencia en las operaciones y, por tanto, en calidad, dado que permite encontrar de manera más rápida los errores, mejorar la funcionalidad de los productos y, consecuentemente, desarrollar productos y servicios más confiables (Nuttal, 2022).

No solo mejora la eficiencia, sino que también impulsa la sostenibilidad en una economía globalizada, ya que puede jugar un rol destacado en el avance hacia Objetivos de Desarrollo Sostenible (ODS) de las Naciones Unidas, como la reducción de la huella de carbono y la promoción del consumo responsable. Además, las tecnologías que dan soporte a la IA, consiguen abordar problemas globales complejos de difícil solución, como el cambio climático, la pobreza o la inseguridad alimentaria (Ciulli & Kolk, 2023). Igualmente, estas tecnologías pueden ayudar a que la fabricación sea más eficiente, eliminando desechos y reduciendo las emisiones de carbono a la atmósfera (Luo & Zahra, 2023).

De igual modo, permiten minorar las emisiones de gases de efecto invernadero (GEI), al brindar información avanzada, basada en datos, sobre la huella de carbono e hídrica, derivada del aumento considerable en la eficiencia de las tareas automatizadas de determinadas actividades como el transporte (Tsolakis et al., 2023). Por ello, las tecnologías se utilizan con frecuencia para calcular las rutas más eficientes en los distintos tipos de transporte (Bidgoli, 2021). Se constata, por tanto, que la IA y el análisis de datos consigue mejorar potencialmente la innovación y el impacto ambiental de las diferentes actividades económicas a largo plazo.

En el cuarto y último grupo, se aborda el impacto en la gestión intercultural y del capital humano en la economía globalizada, dado que en las empresas multinacionales desarrollan su actividad laboral personas de diferentes países con culturas distintas. Para facilitar estas relaciones, los sistemas utilizan software y programas de procesamiento del lenguaje natural que permiten ayudar en la traducción y facilitar comunicaciones más simples en equipos de trabajo virtuales y localizados en distintos puntos del mundo.

Así, algunas aplicaciones tienen la capacidad de realizar traducción simultánea entre idiomas y facilitar reuniones interculturales (Zoom, 2023), proporcionando mayor eficiencia que los sistemas de traducción humana tradicionales; además de que también puede responder a órdenes y preguntas habladas o escritas, lo que permite mejorar la comunicación entre personas de diferentes culturas y tener efectos beneficiosos en las colaboraciones interculturales (Szkudlarek et al., 2020). Por tanto, las reuniones virtuales han supuesto un gran avance, al tiempo que han superado barreras anteriores, en la gestión de las relaciones entre personas de diferentes culturas (OCDE, 2022).

En este entorno multicultural, se necesita desarrollar una gestión internacional del capital humano, siguiendo las directrices estratégicas de las empresas en un entorno global dinámico, interconectado y altamente competitivo (Tarique et al., 2022), y aquí es donde el uso de la tecnología podría ayudar a respaldar decisiones más informadas para satisfacer las necesidades de los empleados (Ahí et al., 2022) y, a su vez, aumentar la creación de valor a nivel global (Chowdhury et al., 2023).

En la competencia mundial por conseguir las personas más creativas y con más conocimiento y capacidades, es necesario que los empleadores adopten herramientas de contratación avanzadas (Chen, 2023) y, algunos investigadores (Budhwar et al. 2022), recomiendan la integración de las tecnologías dentro de los procedimientos y técnicas de gestión de recursos humanos, como la planificación, selección, reclutamiento y capacitación. Tales actividades se pueden realizar por su capacidad de procesar rápidamente datos complejos y proporcionar información más precisa (Budhwar et al., 2022). No obstante, como este autor apunta, la utilización e implementación de la IA en la gestión del capital humano sigue siendo limitada y fragmentada, por lo que es necesario seguir explorando e investigando este importante activo de la empresa.

Las tecnologías más utilizadas en la gestión del capital humano son el procesamiento del lenguaje natural, las ANN y el DL, proporcionando beneficios en los procesos de contratación, así como en la promoción laboral, selección y evaluación de candidatos y su coordinación (Black & Esch, 2020). También facilita la selección de solicitudes al establecer un modelo del candidato ideal basado en otros exitosos anteriores, prediciendo así quién es el candidato más adecuado (Ore & Sposato, 2021).

Además, pueden ayudar a desarrollar preguntas de entrevista y los “chatbots” informar a los solicitantes sobre la etapa de su solicitud y responder inquietudes relevantes sobre la empresa, el salario, forma más adecuada de vestir para la entrevista o la fecha de inicio del trabajo (Black & Esch, 2020). Todo ello mejora los tediosos sistemas de contratación, facilita una mejor selección y reduce los tiempos de respuesta (Horodyski, 2023).

Las capacidades de las nuevas tecnologías permiten a las empresas multinacionales que trabajan con capital humano heterogéneo, conseguir objetividad y neutralidad en los procesos de selección y contratación (Budhwar et al., 2022). También, la integración de esta tecnología en la gestión del capital humano tiene implicaciones estratégicas, porque reorganiza el diseño y la dinámica del trabajo dentro de la empresa global (Vrontis et al., 2021).

Otro elemento de gran interés, dentro del capital humano, es que según estimaciones del Fondo Monetario Internacional (FMI) (Georgieva, 2024, Gerente del FMI)⁶, en torno a un 40% del empleo mundial podrá estar afectado por ella. Este indicador se corresponde con un 60% de trabajos de alta cualificación, posicionados en las economías desarrolladas; un 40% en países emergentes y el 20% en aquellos de bajos ingresos. Así, en las economías desarrolladas, de ese 60%, en torno a la mitad podría beneficiarse de la IA y el resto llevaría a una reducción de la mano de obra o incluso a su desaparición. En el resto de países, las nuevas tecnologías no causarían tanto deterioro en la contratación por no disponer de la infraestructura ni el personal cualificado para su uso y aplicación (Figura 2).

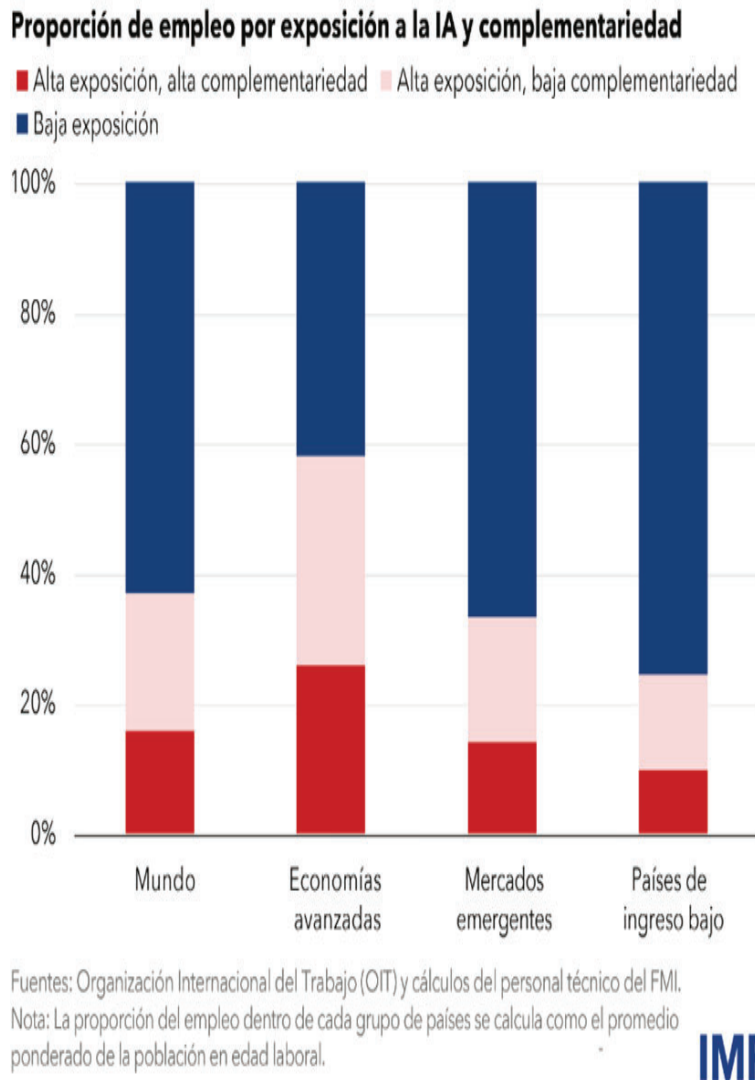


Figura 2. Proporción de empleo por exposición a la IA y complementariedad. Fuente FMI.

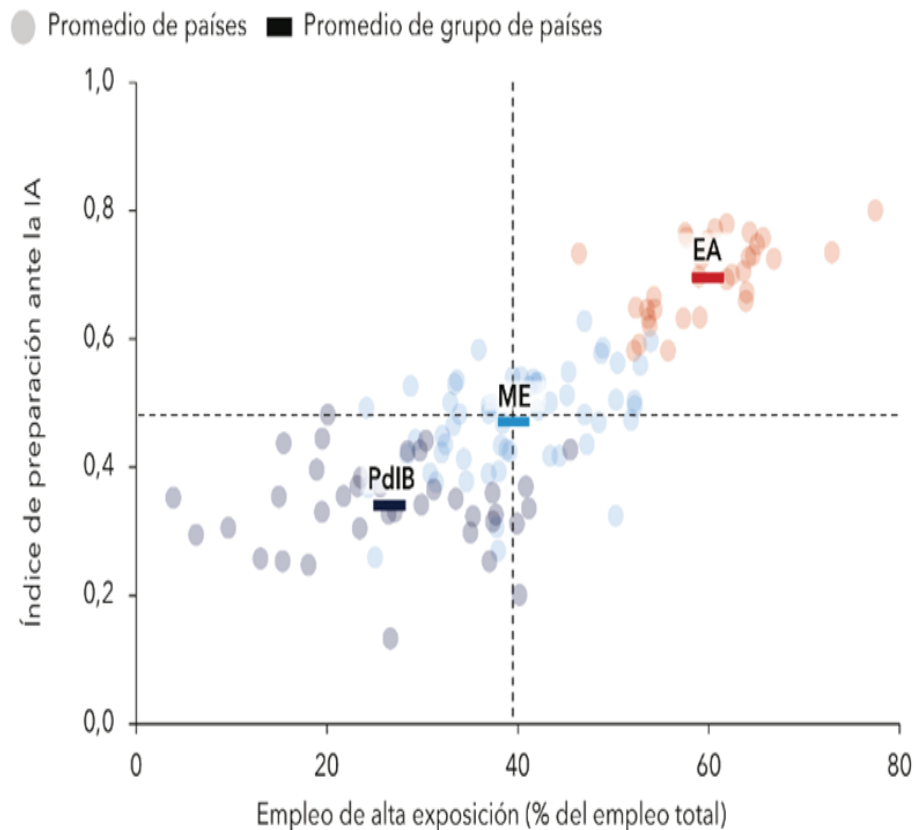
⁶ Estimaciones del FMI – (<https://www.imf.org/es/Blogs/Articles/2024/01/14/ai-will-transform-the-global-economy-lets-make-sure-it-benefits-humanity>)

Otro aspecto importante es el índice que el FMI ha desarrollado para medir el nivel de cualificación de las personas en las nuevas tecnologías aquí estudiadas, que incluye aspectos como infraestructura digital, innovación, mercado laboral o cuestiones éticas. Se aplicó en 125 países, siendo las economías más ricas y algunas emergentes las más preparadas, frente a las de bajos ingresos, aunque con amplias diferencias. Los países mejor posicionados son Singapur, Estados Unidos y Dinamarca (Figura 3).

Ventaja de las economías avanzadas

Los países más ricos suelen estar mejor preparados para adoptar la IA.

Índice de preparación ante la IA y proporción de empleo en ocupaciones de alta exposición



Fuentes: Banco Mundial, Foro Económico Mundial, Instituto Fraser, Naciones Unidas, OIT, Unión Internacional de Telecomunicaciones, Unión Postal Universal y cálculos del personal técnico del FMI. Notas: El gráfico refleja 32 economías avanzadas, 56 economías de mercados emergentes y 37 países de ingreso bajo. Las líneas punteadas de referencia se derivan de los valores medianos del Índice de preparación ante la IA y el empleo de alta exposición.

IMF

Figura 3. Ventajas de las economías avanzadas. Fuente FMI⁷.)

⁷ Ventajas de economías avanzadas – FMI - <https://www.imf.org/es/Blogs/Articles/2024/01/14/ai-will-transform-the-global-economy-lets-make-sure-it-benefits-humanity>

Así pues, los países desarrollados deben apostar por la innovación y el uso de la IA, con normas y leyes que permitan su desarrollo para el bien y seguridad de la humanidad. A las economías emergentes y en desarrollo se les debe apoyar decididamente con inversiones y mano de obra competente en las nuevas tecnologías que se abren paso.

CAPÍTULO II. MÉTODOS EMPLEADOS EN LA INVESTIGACIÓN REALIZADA

En el capítulo anterior se ha realizado un análisis de la IA y su posible aplicación a la toma de decisiones en las organizaciones empresariales, al mismo tiempo que se han descrito, de forma general, las distintas metodologías generales que pueden aplicarse a estos procesos de decisión empresarial.

Procede, por tanto, analizar y profundizar en los métodos que se han considerado más idóneos para desarrollar los trabajos de investigación propuestos, con el propósito principal de aplicar de manera acertada el análisis de los datos, comprender los resultados que se esperan obtener y poder valorar su interpretación.

Para desarrollar esta investigación se van a utilizar diferentes datos económicos que, una vez modelizados, deberán proporcionar información certera para la toma de decisiones. En nuestro caso, partimos de datos de series temporales que, mediante el análisis de sus componentes, deben aportarnos información para elaborar predicciones.

Existen distintos tipos de modelos para realizar este análisis. De entre ellos, y para esta investigación, se han utilizado el “Modelo autorregresivo integrado de media móvil estacional (SARIMA)” y los “Modelos de redes neuronales artificiales”.

Así, en el primer apartado se describe la evolución y el funcionamiento del Modelo SARIMA, pasando a continuación a estudiar las redes neuronales mediante la aplicación de tres métodos neuronales válidos para el pronóstico de series temporales de datos, como son los “Non Linear Autoregressive (NAR)”, “Non Linear Input-Output (NIO)” y “Non Linear Autoregressive with Exogenous Input (NARX)”.

Modelos autorregresivos. Modelo SARIMA

Una breve descripción de la evolución y desarrollo de los denominados genéricamente “modelos autorregresivos”, comienza con el proceso autorregresivo, para, a continuación, definir el proceso de media móvil, obteniéndose el proceso autorregresivo y de media móvil denominado “Modelo ARMA”. Este modelo evolucionó hacia un proceso autorregresivo integrado de media móvil, que es el “Modelo ARIMA”, para llegar al modelo autorregresivo integrado de media móvil estacional, llamado “Modelo SARIMA”, que es el utilizado en este trabajo. Para comprender mejor esta evolución, a continuación se describe el proceso.

MODELOS PREDECESORES DEL MODELO SARIMA

Los primeros procesos estacionarios que se estudiaron fueron los procesos autorregresivos, que consisten en representar un proceso aleatorio en el que una variable de salida depende linealmente de sus valores pasados.

De este modo, la regresión de una variable y_t sobre y_{t-1} es una autorregresión de primer orden, que se expresa como $AR(1)$. La notación $AR(p)$ representa un modelo autorregresivo de orden p . El modelo $AR(p)$ se define como sigue a continuación:

$$x_t = c + \sum_{i=1}^p \varphi_i x_{t-i} + \varepsilon_t$$

donde $\varphi_1 \cdots \varphi_p$ son los parámetros del modelo, c es una constante y ε_t es el ruido blanco como la aleatoriedad⁸.

Cuando un proceso autorregresivo (AR), incluye el proceso de la media móvil (MA), da lugar al “Modelo ARMA”, si la variable dependiente tiene las características regresivas y de la media móvil al mismo tiempo.

Pero hay series temporales económicas que no son estables, ya que su media, varianza y autocorrelaciones no son constantes, porque están determinadas por el tiempo. En este caso, se les considera variables integradas (I). Tal concepto (I) ha permitido al “Modelo ARMA” evolucionar hacia el denominado “Modelo de Medias Móviles Integradas Autorregresivas (ARIMA)”.

El Modelo ARIMA relaciona el valor actual de una serie temporal de datos con sus valores pasados, teniendo en cuenta un término de error aleatorio. Este modelo utiliza los parámetros “p”, “d” y “q”. El primero, “p”, representa el número de valores retrasados o términos autorregresivos e indica cuántos valores pasados se usan para predecir el valor actual. El parámetro “d” identifica el grado de diferenciación o integración, indicando la cantidad de veces que se debe diferenciar la serie para hacerla estacionaria y, así, tratar de eliminar las tendencias y poder hacerla más predecible. Por último, “q”, representa el número de términos de media móvil o términos de error del modelo, para tratar de encontrar la relación entre el valor actual y los errores pasados cometidos por el modelo.

Por tanto, si se pretende discriminar una serie temporal “d” veces para hacerla estable y, después, emplear el Modelo ARMA (p, q), podemos indicar que la serie primera es una serie de tiempo autorregresiva integrada de media móvil ARIMA (p, d, q), en la que “p” es el número de términos autorregresivos, “d” las veces que esta serie debe

⁸ Modelo autoregresivo – IBM - <https://www.ibm.com/es-es/topics/autoregressive-model>.

ser diferenciada para que sea estacionaria y “q” el número de términos de la media móvil (Gujarati y Porter, 2010).

Para realizar predicciones, como es nuestro caso, es necesario que las características de las series de datos sean constantes en el tiempo y, también, en periodos de tiempos futuros. El motivo para necesitar información estacionaria se basa en que cualquier patrón desarrollado según tales datos sea considerado estacionario o estable, para tener una base sólida de predicción (Michael, 1987).

MODELO SEASONAL AUTO-REGRESSIVE INTEGRATED MOVING AVERAGE (SARIMA).

El modelo autorregresivo integrado de media móvil estacional se considera como una extensión del modelo ARIMA no estacional, explicado anteriormente, orientado hacia el tratamiento de datos con patrones no estacionales, teniendo en cuenta las dependencias de estos datos tanto a corto como a largo plazo.

Parte de la combinación conceptual de los modelos autorregresivos (AR), integrados (I) y de media móvil (MA) con componentes estacionales, añadiendo tres nuevos hiperparámetros que permiten determinar la autorregresión (AR), la diferenciación (I) y la media móvil (MA) para el componente estacional de la serie, además de un nuevo parámetro para el período de estacionalidad, llamado “s”.

Por tanto, este modelo parte de los tres parámetros: p, d, y q del modelo ARIMA, a los que se añaden cuatro nuevos, denominados: P, D, Q y s. Los tres primeros son similares a los parámetros p, d, y q, pero se aplican al componente estacional y el parámetro s representa la duración del ciclo estacional.

Para comprender mejor el Modelo SARIMA, se identifican y explican los cuatro componentes del nombre, como se indica a continuación:

1. Componente estacional: La letra “S” del modelo se corresponde con la estacionalidad en los patrones repetitivos de los datos, los cuales pueden ser anuales, trimestrales, mensuales, etc. y trata de identificar y modelar el componente estacional de los datos, aspecto clave en el modelo.
2. Componente autorregresivo: Las siguientes letras “AR” se refieren al aspecto autorregresivo que trata de modelar la relación entre los datos actuales y sus valores pasados, calculando la correlación de los datos con ellos mismos a lo largo del tiempo, es decir su autocorrelación. C
3. omponente integrado: Se corresponde con la letra “I” y se refiere a la diferenciación necesaria para transformar los datos no estacionarios en

estacionarios. Indica el número de diferencias necesarias hasta llegar a la estacionalidad.

4. Componente de media móvil: Las últimas letras “MA” del nombre del modelo se refieren a la media móvil y trata de modelar la dependencia entre el punto de datos actual y los errores pasados en las predicciones realizadas. También se puede entender que este componente intenta identificar el ruido a corto plazo que tienen los datos.

Hemos indicado que un elemento clave del modelo es la estacionalidad, y para comprender este concepto consideramos necesario definir la diferenciación estacional (D), como el proceso de restar los valores de la serie temporal de datos por un rezago equivalente a la estacionalidad. Ello permite eliminar el componente estacional y tener unos datos más estacionales, con lo que el modelado será más sencillo.

Este modelo se representa como SARIMA (p, d, q) (P, D, Q, s), reflejando entre paréntesis sus siete componentes. El significado de cada uno se expone seguidamente:

- p: componente autorregresivo de orden p.
- d: componente integrado de orden d.
- q: componente de media móvil de orden q.
- P: componente autorregresivo estacional de orden P.
- D: componente integrado estacional de orden D.
- Q: componente de media móvil estacional de orden Q.
- s: periodo estacional que nos indica la duración del ciclo estacional.

En la presente investigación se ha elegido el Modelo SARIMA, porque es uno de más recomendados para la predicción de datos económicos y, además, se ajusta a algunas particularidades del trabajo que se pretende desarrollar. Como el uso de datos con patrones estacionales, es considerado preciso en las predicciones a largo plazo, permite cierta flexibilidad en la representación de los datos y puede realizar un modelado completo de las series temporales⁹.

Modelos neuronales para la predicción de series temporales

Las ANN pueden considerarse como el fundamento soporte de los métodos aplicados en nuestra primera investigación como son el NAR, el NIO y el NARX, por ello, procedemos a realizar una descripción más profunda de las bases de funcionamiento de las redes neuronales, con el propósito de comprender mejor el fundamento de los métodos aplicados a la investigación.

⁹ Modelo SARIMA - <https://www.tecnicasdetrading.com/2024/07/modelo-sarima.html>

Una vez planteado lo que es una red neuronal, su importancia, su utilización, su funcionamiento y los diferentes tipos de redes neuronales, pasaremos a describir cada uno de los métodos utilizados en indicados en el párrafo anterior.

REDES NEURONALES

Las ANN pueden considerarse como modelos de ML, e indicábamos en el capítulo anterior, que se consideran como una metodología de la IA que enseña a los ordenadores a procesar datos de una forma similar a como lo hace el cerebro humano. Por tanto, es un proceso de ML, también llamado por algunos ingenieros de DL, en el que se usan nodos o neuronas interconectadas en una estructura de capas parecida al cerebro humano.

Así mismo, el objetivo de las redes neuronales es solucionar problemas complejos para ayudar a los dispositivos tecnológicos a tomar decisiones mejores, dado que son capaces de ejercitar y configurar las relaciones entre datos complejos y así establecer predicciones y simulaciones con gran precisión (Jumper et al., 2021). De ahí su importancia para un proceso decisional acertado, rápido y rentable para la empresa.

También se apuntaba en esa investigación sobre sus interesantes aplicaciones empresariales como, la visión artificial, el reconocimiento de voz o el procesamiento del lenguaje natural, entre otros. Pero en lo que respecta a esta investigación, nos centramos en su uso en la empresa, dado que puede aplicarse en distintas actividades productivas como marketing, finanzas, demanda, procesos, calidad, etc.

En este sentido, las ANN permiten realizar búsquedas y otras actuaciones en cualquier actividad productiva, para proponer sugerencias de actuación y, también, utilizarse para analizar comportamientos, descubrir y visualizar nuevos productos o nuevos servicios en los clientes que permitan anticiparse a la futura demanda y, con ello, generar un mayor valor añadido para la empresa (Toorajipour et al., 2021).

La arquitectura y el funcionamiento de estas redes, se asimila al del cerebro humano donde sus células, neuronas, forman una red compleja interconectada, enviándose impulsos de carga eléctrica entre sí, que permiten al cerebro humano procesar información. De la misma manera una red neuronal se conforma con neuronas artificiales que colaboran entre ellas en la resolución de problemas. Para comprender mejor este importante proceso, se puede indicar que las neuronas artificiales o nodos son los módulos de software y las redes neuronales artificiales, los algoritmos que se usan en los sistemas informáticos para realizar cálculos matemáticos, estando inspirados estos últimos en la selección natural y la reproducción biológica (Sang, 2021).

Cualquier red neuronal elemental, tiene las neuronas interconectadas a través de tres niveles o capas:

- Un nivel de capa de entrada, donde los datos externos entran en la red. Aquí sus nodos procesan los datos, los clasifican, los analizan y los trasladan al siguiente nivel o capa.
- El segundo nivel, denominado también capa oculta, parte de primer nivel y de otras capas ocultas, ya que pueden existir varias capas ocultas, analizando y procesando la salida de la capa anterior y pasando la información a la siguiente capa.
- El tercer nivel sería de salida y en esta capa se proporciona la última información obtenida del proceso de tratamiento de todos los datos. En las situaciones de clasificación multiclase, esta última capa permite tener varios nodos de salida.

Avanzando más, las redes neuronales de DL, tienen distintas capas ocultas con millones de neuronas artificiales interconectadas. Tales redes necesitan más entrenamiento que otros métodos como el ML. Podríamos decir que estas últimas requieren de numerosos ejemplos de datos de entrenamiento, lo que les confiere capacidad de aprender e identificar patrones (Chan, 2017), mientras que las redes más simples solo serían necesarios cientos o miles.

El proceso de entrenamiento consiste en adiestrar a la red neuronal a ejecutar una determinada actividad, de tal manera que aprenden procesando grandes cantidades de datos. Así en el aprendizaje supervisado se proporcionan conjuntos de datos que ofrecen respuestas correctas y la ANN va aumentando su conocimiento, tratando de proporcionar la solución al problema.

ALGORITMO	EXPLICACIÓN
Levenberg-Marquardt (LMA)	Algoritmo para la búsqueda de un mínimo en una función y puede utilizar la reprogramación para el entrenamiento.
Batch Gradient Descent	Algoritmo de optimización para encontrar mínimos locales.
Gradient Descent with Momentum	Mejora el anterior ya que promedia los gradientes mediante iteraciones.
Adaptive Learning Rate Backpropagation	Aprendizaje automático mediante la búsqueda progresiva de mejores resultados, utilizando los obtenidos anteriormente.
Gradient Descent with Momentum and Adaptive Learning Rate	Basado en los dos anteriores para intentar obtener con mayor rapidez el mínimo de la función de error.

Scaled Conjugate Gradient	Mejora la velocidad de convergencia del anterior por el descenso del gradiente.
Broyden–Fletcher–Goldfarb–Shanno Backpropagation (Quasi-Newton)	Metodología iterativa casi newtoniana para abordar la optimización de cuestiones con datos no lineales.

Tabla 1. Algoritmos de entrenamiento para redes neuronales de aprendizaje supervisado. Fuente: Elaboración propia.

A modo de resumen podemos indicar que, la IA es una ciencia que investiga las metodologías que permitan capacitar a las máquinas realizar las tareas que necesitan la inteligencia humana. Los modelos de ML se basan en una técnica derivada de la anterior ciencia que permite a los dispositivos tecnológicos el acceso a grandes cantidades de datos y les adoctrina para aprender de ellos. Los programas o software de los modelos de aprendizaje automático buscan los patrones de los datos existentes y aquéllos los replica a la información nueva para así poder tomar decisiones acertadas. Las redes neuronales artificiales son modelos de aprendizaje máquina basados en el funcionamiento de las neuronas biológicas y pueden utilizarse para resolver distintos problemas.

En esta investigación se han utilizado para el análisis y predicción de series temporales en las que se realiza aprendizaje supervisado, llevando a cabo experimentos con muchas combinaciones de valores a través de distintas pruebas. Cada experimento es el resultado de combinar distintos valores (número de neuronas en capa oculta y número de retardos en las distintas bases de datos) junto con los algoritmos de entrenamiento del modelo neuronal, que utiliza el software Matlab, y se reflejan en la tabla 1.

Para adaptar los correspondientes parámetros, se ha procedido a hacer experimentos con muchas combinaciones de valores, realizando distintas pruebas. Así, cada experimento es el resultado de combinar distintos valores de los parámetros (número de neuronas en capa oculta y número de retardos) y distintos algoritmos de entrenamiento del modelo neuronal. Una vez conocido el valor de salida real (que proviene del aprendizaje supervisado), se puede medir el error obtenido por el modelo en cada experimento y, para cuantificar este error, se ha utilizado la métrica denominada *Mean Squared Error* (MSE), que se representa según la fórmula siguiente:

$$MSE = \frac{1}{N} \sum_{i=1}^N (t - a)^2$$

donde t es el valor a rededir de la serie y a el valor real obtenido en el modelo.

NON LINEAR AUTOREGRESIVE (NAR)

Explicadas las redes neuronales y los algoritmos de entrenamiento, pasamos a especificar más concretamente los modelos utilizados en esta parte de la investigación. El primer modelo es el denominado NAR (*Nonlinear Autoregressive*), que permite una predicción en el instante de tiempo “ t ” de una serie temporal (y), a partir únicamente de valores de la propia serie temporal en instantes anteriores de tiempo y se representa conforme a la función siguiente:

$$y(t) = f(y(t-1), \dots, y(t-n_y))$$

donde n_y es el número de retardos que se consideran en el modelo y se refieren a la cantidad de valores anteriores de la serie que se tienen en cuenta para calcular uno nuevo.

Para su puesta en funcionamiento, puesto que se utiliza MATLAB¹⁰, se construye una red neuronal con propagación hacia adelante que incorpora una capa oculta, además de contar con una función de activación tangente hiperbólica y una única neurona en la capa de salida con función de activación lineal. Adicionalmente, se utilizan varios algoritmos para el adiestramiento y mejora del modelo. El funcionamiento del NAR para diez neuronas se describe en la Figura 4.




Figura 4. Representación de MATLAB para modelo NAR con 10 neuronas en capa oculta y una salida con un retardo de 6. Fuente: The Mathworks Inc.

Con el Modelo NAR se han realizado bastantes experimentos, utilizando distintos valores para los dos parámetros ajustables y con el algoritmo de entrenamiento, que se corresponde con el número de neuronas y de retardos (n_y), relativos a la serie de entrada de sus datos previos.

¹⁰ MATLAB. Software comercial, que es un sistema de cómputo numérico, y ofrece un entorno de desarrollo integrado con un lenguaje de programación propio.

NON LINEAR INPUT-OUTPUT (NIO)

Con el segundo Modelo NIO (*Non linear Input-Output*), al igual que en el anterior NAR, también se realiza una predicción de futuros valores de una serie temporal “ $y(t)$ ” e, igualmente, tal predicción se ejecuta a partir exclusivamente de valores de una serie temporal en instantes anteriores de tiempo. Pero, frente al NAR, la serie utilizada no es la entrada anterior, sino una entrada llamada exógena. La ecuación que describe de manera detallada este modelo es la siguiente:

$$y(t) = f(x(t-1), \dots, x(t-n_y))$$

donde n_y es el número de retardos que se consideran, y representan los valores anteriores de la serie exógena necesarios para obtener la predicción de uno nuevo.

Para su implementación, al utilizar MATLAB, se configura una red neuronal con propagación hacia adelante, incorporando una capa oculta que incluye una función de activación tangente hiperbólica y, también, una única neurona en la capa de salida, cuya función de activación es lineal, como se puede observar en la Figura 5. Además, se debe indicar que se emplean los algoritmos ya descritos más arriba para ejercitar el Modelo NIO.




Figura 5. Representación de MATLAB para modelo NIO con 5 neuronas en capa oculta y una entrada exógena con 5 valores y retardo de 8. Fuente: The Mathworks Inc.

De manera idéntica que en el Modelo NAR, en el NIO se abordan distintos ensayos, testando con bastantes valores para los dos parámetros ajustables, además de con el algoritmo de entrenamiento, es decir, número de neuronas y número de retardos (n_x).

NON LINEAR AUTOREGRESSIVE WITH EXOGENOUS INPUT (NARX)

Para completar la parte experimental de esta investigación, se ha utilizado el modelo neuronal denominado NARX (*Non linear Autoregressive with Exogenous Input*) (Leontaritis & Billings, 1985). El mismo es una formulación general para realizar una predicción de valores de una serie temporal “ $y(t)$ ”, tomando en consideración valores anteriores de la serie primera y de otra distinta “ $x(t)$ ”. Su descripción se ajusta a la siguiente fórmula.

$$y(t) = f(y(t-1), \dots, y(t-n_y), x(t-1), \dots, x(t-n_x)) + \xi(t)$$

donde n_y es el número de retardos en la salida (feedback), n_x los retardos en la entrada, y $\xi(t)$ término asociado a ruido (asumido como gaussiano y blanco, generalmente).

La aplicación de este modelo consiste en descubrir la función no-lineal que aborda el mapeo entre los datos de entrada (valores anteriores de x e y) y la salida (valor a pronosticar de la serie y). Así, el Modelo NARX se considera una extensión no-lineal de los conocidos Modelos ARX; que son de características dinámicas lineales de autorregresión con variables exógenas.

En esta investigación se emplea una implementación neuronal de este modelo en MATLAB, de tal forma que se crea una red neuronal con una única capa oculta que dispone de una función de activación tangente hiperbólica y una única neurona en la capa de salida con función de activación lineal. Esta red neuronal toma como entrada tanto los valores de la propia serie a predecir “ $y(t)$ ”, como de la serie externa “ $x(t)$ ”. Tal configuración se ha representado en la Figura 6.




Figura 6. Representación de MATLAB para modelo NARX con 30 neuronas en la capa oculta y una neurona con la capa de salida, una entrada exógena con 5 valores y un retardo de 4 y una única salida con retardo de 10. Fuente: The Mathworks Inc.

Algunos investigadores indican que la aplicación de Modelos NARX con disminución de gradiente para el pronóstico de series de orden sucesivo de más antiguo a más actual con grandes dependencias temporales, es más eficiente que el uso de modelos basados en Perceptrones Multicapa (Lin et al., 1998). En esta misma línea, otros autores, también han concluido que este modelo da el mejor rendimiento respecto de otras implementaciones neuronales, para la predicción de series temporales (Menezes & Barreto, 2008). Estas consideraciones de autores relevantes han sido determinantes para justificar el empleo del Modelo NARX en esta investigación.

PARTE II: INVESTIGACIONES REALIZADAS

CAPÍTULO III. ANÁLISIS DE SERIES TEMPORALES PARA LA PREDICCIÓN DEL PRECIO DEL ACERO LAMINADO EN CALIENTE EN ESPAÑA, MEDIANTE MODELOS NEURONALES NO LINEALES

En epígrafes anteriores se ha realizado un análisis del estado del arte y de metodologías aplicadas a esta investigación. En este capítulo pasamos a describir las investigaciones realizadas, que han sido publicadas en revistas científicas.

Resumen: En el contexto industrial, el acero es una materia prima ampliamente utilizada con aplicaciones en muchos campos diferentes. Debido a su alto impacto en la actividad de muchas industrias en todo el mundo, la predicción de su precio es de suma importancia para una gran cantidad de empresas. En este trabajo, se aplican por primera vez modelos neuronales no lineales a diferentes conjuntos de datos con el fin de validar su idoneidad para predecir el precio de este commodity. En particular, se aplican por primera vez de forma innovadora los modelos de redes neuronales NAR, NIO y NARX para predecir el precio del acero laminado en caliente en España. Además de esta variedad de modelos, se comparan y analizan diferentes conjuntos de datos que consisten en un conjunto de variables heterogéneas de los últimos siete años y relacionados con el precio de este commodity. Los resultados mostraron que NARX es el modelo con mejor desempeño cuando se utilizan como entrada de este modelo predictivo el precio de las materias primas utilizadas para producir acero y los precios de las bolsas de valores de tres grandes empresas productoras de acero a nivel mundial. En consecuencia, este resultado puede impulsar la aplicación de Machine Learning en las empresas, con el fin de programar las operaciones de suministro de acuerdo con la previsión de precios.

1.-Introducción

La primera y segunda revolución industrial estuvieron influidas por el descubrimiento del acero y la mejora de su tecnología de producción. En las revoluciones industriales posteriores, el acero ha permanecido y continúa siendo esencial en la modernización del mundo. Así, la industria siderúrgica es esencial para el progreso económico, debido al papel fundamental que juega el acero en el desarrollo de la infraestructura y la economía en general.[1]

El acero es una aleación de carbono (entre un 0,2% y un 2%) y mineral de hierro, con la adición de otros minerales para modificar sus propiedades. Además, el acero es un material altamente reciclable, ya que también puede producirse a partir de chatarra de acero, lo que permite una verdadera economía circular. Por otra parte, la versatilidad del acero en cuanto a formas y tamaños permite su uso en una amplia gama de

aplicaciones, desde pequeños componentes hasta proyectos estructurales a gran escala. [2]

En 2019, la producción mundial fue de aproximadamente 1.870 millones de toneladas métricas de acero crudo y 530 millones de toneladas métricas de chatarra de acero (según la Asociación Mundial del Acero), alrededor de 2.500 millones de toneladas métricas de mineral de hierro (según el Servicio Geológico de Estados Unidos) y 1.100 millones de toneladas métricas de carbón metalúrgico (según la Agencia Internacional de Energía AIE). [3]

Actualmente, existen dos rutas principales en el proceso de fabricación de acero, el horno básico de oxígeno (BOF) y el horno de arco eléctrico (EAF). El proceso BOF es una ruta primaria que utiliza principalmente mineral de hierro y carbón para producir acero. Por otro lado, el proceso EAF es una ruta secundaria que emplea chatarra de acero para producir acero. El proceso EAF ha ganado una importancia considerable debido a la sostenibilidad y la eficiencia energética que ofrece. El uso de chatarra de acero reduce la necesidad de materiales vírgenes, lo que reduce los requisitos generales de energía y reduce las emisiones de carbono. [4]

El acero no es un producto homogéneo y se puede clasificar según diversos criterios. Uno de ellos es la forma física del acero, que puede ser en bobinas, en acero plano o en acero largo. El acero también se puede clasificar según su etapa de transformación, que incluye el acero laminado en caliente, el laminado en frío y el galvanizado. [4]

El uso generalizado del acero en muchas industrias hace que su precio sea un factor crítico que afecta la competitividad de muchas empresas. Predecir el precio del acero es esencial para tomar decisiones comerciales informadas relacionadas con la compra y venta de acero.

El precio del acero es muy volátil y sufre cambios frecuentes que son difíciles de predecir. El costo de las materias primas, como el mineral de hierro, el carbón y la chatarra, es un factor importante que influye en el precio del acero. Además, el costo del transporte, las condiciones macroeconómicas y otros factores relacionados con el mercado también contribuyen a la fluctuación de los precios del acero. [5], [6]

Además, el precio del acero varía entre países debido a factores locales como aranceles, demanda, impuestos y otros factores. La evolución de los precios del acero en un país en particular a menudo está vinculada a la evolución global de los precios del acero. [7]–[9] La razón de esto es que el acero es un producto global, que está correlacionado con las condiciones del comercio internacional. [10]

El primer objetivo de este trabajo es evaluar la correlación con el precio del acero BLC en España de un grupo de diferentes factores (precios bursátiles de las empresas siderúrgicas, indicadores económicos, precios de las materias primas utilizadas para

producir acero o precio de otras materias primas). Y el segundo es evaluar qué modelos neuronales no lineales (NIO, NAR, NARX) pueden predecir con menor error el precio del acero, para los diferentes factores.

2.- Trabajos relacionados

Los estudios de predicción de los precios del acero son escasos y parece haber una brecha en la investigación para mejorar la precisión de las previsiones. [11], [12] Sin embargo, esta predicción es digna de mención porque el precio del acero influye en el precio de otros productos, así como en la evolución de los precios de las acciones de las empresas siderúrgicas. [13] Por otro lado, el precio de algunos productos está correlacionado con el precio del acero, como el precio de los metales o el petróleo, que son indicadores de las condiciones macroeconómicas y especulativas del mercado. [14]

En general, los precios de los productos de acero tienden a seguir una tendencia similar, y la bobina laminada en caliente (HRC) suele servir como referencia debido a que representa el mayor volumen de exportaciones de acero. Por lo tanto, para los fines de este estudio, se utilizará el precio de la HRC. [15]

Se han empleado numerosos modelos computacionales para la previsión de precios del acero, incluido el modelo de media móvil integrada autorregresiva (ARIMA) [16], [17] y el modelo de memoria a largo plazo (LSTM) [18]. Las redes neuronales han demostrado ser un enfoque adecuado para la predicción de precios de series temporales debido a su capacidad para capturar características no lineales a través de capacidades de autoaprendizaje. [19], [20]

Las redes neuronales no lineales se han utilizado en varios campos, incluida la logística [21] y la agricultura de precisión [22]. Sin embargo, este estudio representa la primera instancia en la que se emplean modelos de redes neuronales no lineales para la predicción de precios del acero.

Desde la misma perspectiva que el presente trabajo, se ha llevado a cabo un estudio preliminar. [23] Basándose en este trabajo seminal, el presente documento contribuye enriqueciendo el conjunto de datos considerados en el estudio, así como la combinación de las diferentes series. Como resultado, se han obtenido resultados interesantes, que respaldan la inclusión de los nuevos datos en la tarea de predicción del precio de la bobina laminada en caliente.

3.- Caso de estudio

Este estudio se centra en el uso de varias redes neuronales para analizar datos históricos y encontrar patrones no lineales que puedan utilizarse para realizar predicciones del precio de la bobina laminada en caliente (BLC) en el mercado español.

La precisión de las predicciones obtenidas por estos algoritmos podría variar dependiendo de la calidad de los datos utilizados, la complejidad del modelo y otros factores. Por lo tanto, se realiza un análisis cuidadoso con diferentes series de datos para determinar cuál contribuye a una predicción más precisa.

El conjunto de datos utilizado para predecir el precio de la bobina laminada en caliente (BLC) en el mercado español proviene de la Unidad de Investigación de Materias Primas de CRU, un proveedor independiente de información sobre el mercado del acero de renombre y líder en el sector. Para estimar el precio, el conjunto de datos se divide en cuatro grupos, que incluyen lo siguiente:

- Serie 1: Este grupo comprende los precios de mercado de tres importantes empresas productoras de acero a nivel mundial, a saber, Posco, ArcelorMittal y NipponSteel. La fuente de datos para este grupo es el precio en tiempo real en USD de NYSE - Nasdaq.
- Serie 2: Este grupo contiene datos relacionados con la situación económica en España, incluyendo tres cuestiones principales: a) Precios (Índice 2010=100): Índice de Precios al Consumo Armonizado, Índice de Precios al Consumo Todos los artículos, Índice de Precios al Productor Todos los Productos Básicos; b) Actividad Económica- Producción Industrial (Índice 2010=100): Índice Total, Índice Manufacturero, Índice Minero; c) Comercio Exterior de Bienes (Dólares de EE.UU.): Valor de las Importaciones (Coste, Seguro, Flete CIF), Valor de las Exportaciones (Franco a Bordo FOB). La fuente de datos para este grupo es el Fondo Monetario Internacional.
- Serie 3: Este grupo incluye los precios de otras materias primas como el Aluminio, el Crudo Brent, el Cobalto, el Cobre, el Crudo Dubai, el Oro, el Plomo, el Molibdeno, la Plata y el Zinc. La fuente de datos para este grupo es también el Fondo Monetario Internacional.
- Serie 4: Este grupo cubre los precios de las materias primas utilizadas en la producción de acero, incluyendo el Índice de Mineral de Hierro, el Índice de Precios al Productor de Hierro y la Chatarra de Acero. La fuente de datos para este grupo es también el Fondo Monetario Internacional.

Además de estas series de datos, también se han estudiado algunas combinaciones de ellas en la presente investigación. El período de tiempo del conjunto de datos corresponde a los años de 2013 a 2019, y consisten en una periodicidad mensual ya que esta es la unidad de tiempo mínima establecida para la indexación de los precios

del acero. Esta periodicidad mensual se considera suficiente para reflejar la volatilidad del precio del acero. [24]

4.-Métodos y contextos experimentales

Con el objetivo de predecir el precio de HRC, las series de datos descritas en la Sección 3 (junto con el precio en sí) se han utilizado para alimentar los siguientes modelos de series temporales [25]: Non-linear Autoregressive (NAR), Non-linear Input-Output (NIO) y Non-linear Autoregressive with Exogenous Input (NARX). Estos son modelos neuronales similares que realizan predicciones sobre una serie temporal (endógena) teniendo en cuenta diferentes datos de entrada; el modelo NAR es un modelo autorregresivo, es decir, utiliza como datos de entrada los datos que se van a predecir y solo estos datos. Por el contrario, el modelo NIO solo utiliza datos de una fuente exógena; es decir, los datos que se van a predecir no se utilizan para la predicción.

Finalmente, el modelo NARX combina estos dos enfoques y utiliza fuentes de datos tanto endógenas como exógenas; es decir, se utiliza la serie de datos que se va a predecir, así como otras fuentes de datos. En el presente estudio el precio es el endógeno, fuente de datos (a predecir), mientras que las cuatro series de datos descritas en la sección 3 y las combinaciones de ellas, son las fuentes de datos exógenas. Matemáticamente, estos modelos pueden definirse formalmente considerando $f(y)$ como la función que se aproximará mediante el modelo no lineal e $y(t)$ como los datos que se predecirán en el instante de tiempo t , utilizando n_y valores previos de los mismos.

De acuerdo con esto, el modelo NAR puede expresarse como se refleja en la fórmula (1):

$$\hat{y}(t) = f(y(t-1), \dots, y(t-n_y)) \quad (1)$$

Como se indicó anteriormente, el NIO utiliza n_x valores previos de una fuente de datos exógena (x) para realizar la predicción, lo cual se representa en la fórmula (2):

$$\hat{y}(t) = f(x(t-1), \dots, x(t-n_x)) \quad (2)$$

El modelo NARX considera fuentes de datos tanto endógenas como exógenas para predecir los valores de $y(t)$, identificado en la fórmula (3):

$$\hat{y}(t) = f(y(t-1), \dots, y(t-n_y), x(t-1), \dots, x(t-n_x)) \quad (3)$$

Para ajustar estos modelos, se deben tener en cuenta diferentes parámetros (descritos en la tabla 1). Los valores presentados para estos parámetros se han seleccionado en función de experiencias previas con los mismos modelos.

<i>Parameter</i>	<i>Selected Values</i>
Number of input delays	{1, 2, 3, 4, 5, 6, 7, 8, 9, 10}
Number of output delays	{1, 2, 3, 4, 5, 6, 7, 8, 9, 10}
Number of hidden neurons	{1, 5, 10, 15, 20}
Training algorithm	{1 - Levenberg-Marquardt, 2 - Batch Gradient Descent, 3 - Gradient Descent with Momentum, 4 - Adaptive Learning Rate Backpropagation, 5 - Gradient Descent with Momentum and Adaptive Learning Rate, 6 - Scaled Conjugate Gradient, 7 - Broyden-Fletcher-Goldfarb-Shanno Backpropagation}

Tabla 1. Parámetros y valores seleccionados para la experimentación.

Para obtener resultados significativos desde un punto de vista estadístico, cada experimento (misma combinación de valores de parámetros) se ha ejecutado diez veces. Como resultado, combinando todos los valores (ver Tabla 1) para los diferentes parámetros, se han ejecutado los siguientes experimentos para cada serie de datos:

NIO: 350

NAR: 350

NARX: 3.500

Esto significa que se han ejecutado 4.200 experimentos para cada una de las series de datos. Como en el presente estudio se consideran siete combinaciones de series de datos, se han llevado a cabo 29.400 experimentos. Además, MATLAB fue la herramienta elegida para entrenar los tres modelos neuronales considerados. Además de que los tres modelos están incluidos dentro de Neural Network Toolbox con una interfaz fácil de usar, se pueden encontrar más detalles de los hiperparámetros de los modelos o de los algoritmos de entrenamiento en la documentación gratuita y en línea de MATLAB.

5.-Resultados obtenidos

En esta sección se describen los resultados de los experimentos realizados sobre el conjunto de datos explicados en la Sección 3 con los modelos y la experimentación descritos en la Sección 4. Para comparar los resultados obtenidos con los diferentes modelos neuronales y configuraciones de parámetros, en esta sección se presentan diferentes tablas que muestran el Error Cuadrático Medio (MSE) promediado, una métrica de rendimiento calculada utilizando los resultados reales y estimados como se muestra en la Ecuación 4. Esta métrica se muestra para las diez ejecuciones realizadas como se muestra en la Sección 4. El error más bajo obtenido para cada uno de los

modelos aplicados (NAR, NIO y NARX) está en negrita. En cada una de estas ejecuciones, el conjunto de datos completo se divide aleatoriamente en tres subconjuntos: uno primero de un tamaño del 70% de los datos para entrenar los modelos neuronales, y dos subconjuntos más de un tamaño del 15% de los datos cada uno para controlar el proceso de entrenamiento con detención temprana (es decir, evitando problemas de sobreajuste) y para probar el rendimiento del modelo entrenado en nuevas muestras no vistas calculando la métrica de rendimiento, respectivamente.

$$MSE = \frac{1}{N} \sum_{t=1}^N (y(t) - \hat{y}(t))^2 \quad (4)$$

Inicialmente, los resultados promedio obtenidos por los modelos neuronales por el número de retrasos de entrada para cada una de las siete series de datos se muestran en la Tabla 2.

<i>N Input Delays</i>	<i>NAR</i>	<i>NIO</i>	<i>NARX</i>
1	44777.62	36811.43	30487.87
2	36811.43	33308.51	561614.03
3	35092.46	36759.93	31346.13
4	37317.69	33868.34	31723.53
5	35941.02	37161.12	32868.78
6	32765.64	41840.80	33015.77
7	29586.15	38956.52	33273.62
8	35067.41	44639.67	35142.19
9	35714.85	46625.89	371782.60
10	27439.20	45676.48	38159.96

Tabla 2. MSE de los resultados obtenidos por los modelos neuronales NAR, NIO y NARX. Los resultados promedio para las siete series de datos se muestran por el número de retrasos de entrada.

De los resultados de la tabla anterior se puede decir que las mejores predicciones se obtienen con un número opuesto de retardos de entrada. Mientras que en el caso del modelo NAR el mayor número de retardos de entrada (10) conduce al menor error, es al revés en el caso de los modelos NIO y NARX; el menor número de retardos de entrada (2 y 1 respectivamente) son los que hacen que estos dos modelos reproduzcan el menor error.

Además de los datos que se muestran en la Tabla 2, los mismos resultados también se reflejan en la Figura 1, donde los resultados MSE promedio a través de diferentes ejecuciones se representan mediante una línea negra vertical dentro de los recuadros y los círculos a la derecha pueden considerarse valores atípicos (es decir, una ejecución

donde el rendimiento del modelo en términos de MSE se desvía fuertemente del promedio).

Este diagrama de cajas reúne los resultados (MSE) obtenidos por todas las ejecuciones que se han llevado a cabo, agrupados por el número de retardos de entrada. Uno de los primeros hechos que se pueden observar en esta Figura es que existe una alta variación entre los resultados para cada uno de los casos (número de retardos de entrada). Cada uno de los casos contiene los resultados de todos los experimentos con los mismos valores para todas las demás alternativas aparte del número de retardos de entrada (modelo neuronal, número de retardos de salida, número de neuronas ocultas y algoritmo de entrenamiento).

Aunque a nivel individual (Tabla 2) los valores más bajos y más altos de retardos de entrada se han identificado como los de mejor rendimiento para los tres modelos neuronales, no se pueden obtener las mismas conclusiones para los tres modelos. 4, 6, 8 y 9 son los valores de retardos de entrada con menor error en términos generales.

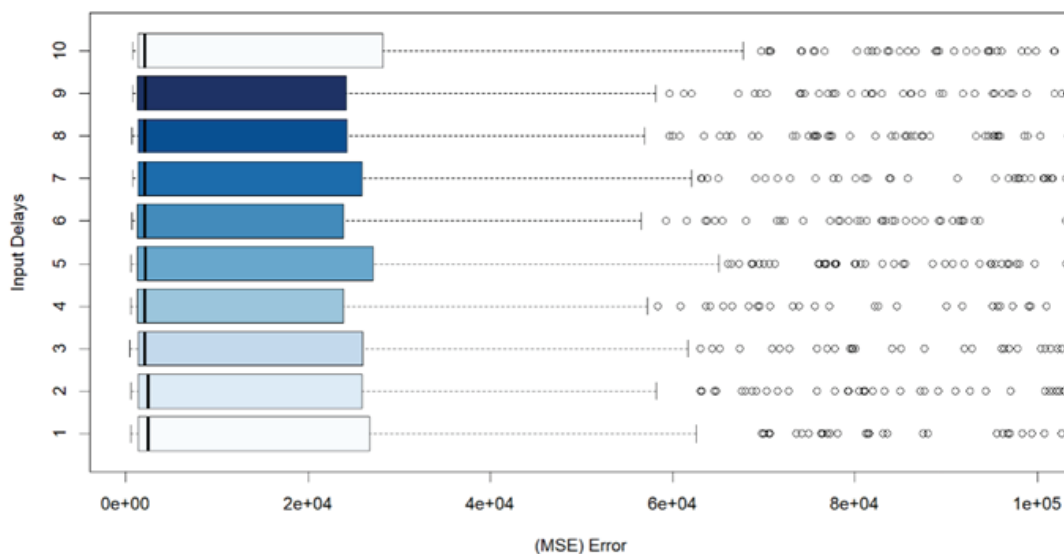


Figura 1. Diagrama de caja que representa el MSE de los resultados obtenidos por los modelos neuronales NAR, NIO y NARX. Los resultados de las 7 series de datos se agrupan por el número de retardos de entrada.

Otro parámetro que debe ajustarse en los modelos neuronales aplicados es el número de neuronas en la capa oculta. Se han analizado cinco casos diferentes para este parámetro en la experimentación y los resultados obtenidos para cada uno de los modelos se muestran en la Tabla 3.

<i>N</i> Neurons	<i>NAR</i>	<i>NIO</i>	<i>NARX</i>
1	9086.54	11099.63	10317.71
5	19673.21	23504.17	190410.26
10	34537.72	37411.27	295214.23
15	48963.24	56398.83	45511.52
20	62996.01	68631.01	58253.53

Tabla 3. MSE de los resultados obtenidos por los modelos neuronales NAR, NIO y NARX. Se muestran los resultados promedio para las siete series de datos por número de neuronas ocultas.

Al considerar el número de neuronas ocultas en la capa oculta, se puede decir lo mismo de los tres modelos aplicados: las mejores predicciones se obtienen con el menor número de neuronas, es decir, 1. Este es claramente el valor de este parámetro que conduce al menor error en todos los casos.

Al igual que en el caso de los retrasos de entrada, también se representan los grupos de resultados por el número de neuronas ocultas (Figura 2). La tendencia es muy clara, como se puede ver en el diagrama de caja: aumentar el número de neuronas en la capa oculta de los modelos neuronales conduce a mayores tasas de error. Se puede ver en la Tabla 4 y al mismo tiempo en la Figura 2: una sola neurona oculta es la mejor opción para los datos y los modelos no lineales que se validan en el presente estudio para predecir el precio del acero BLC.

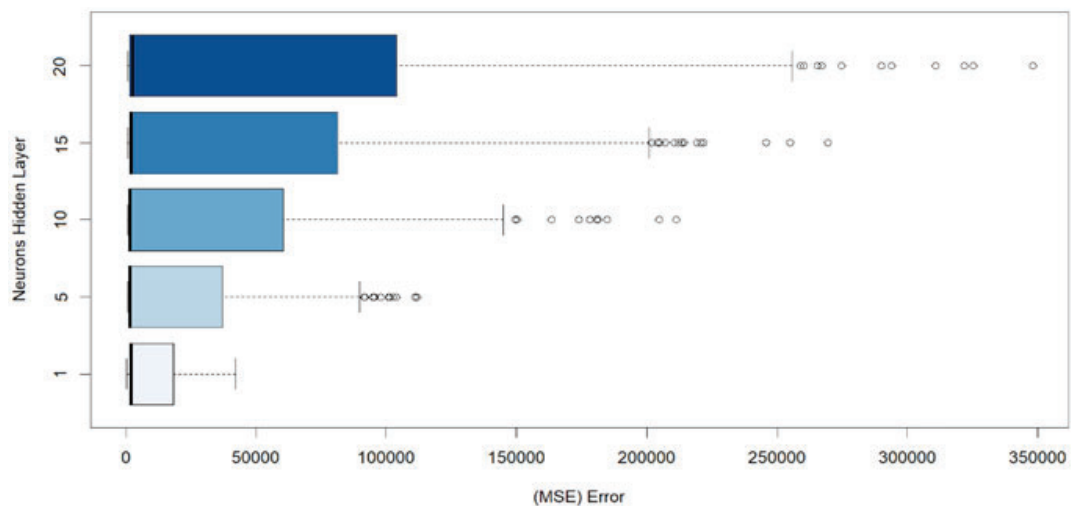


Figura 2. Diagrama de caja que representa el MSE de los resultados obtenidos por los modelos neuronales NAR, NIO y NARX. Los resultados para las 7 series de datos se agrupan por el número de neuronas ocultas.

<i>Training Algorithm</i>	<i>NAR</i>	<i>NIO</i>	<i>NARX</i>
1	2029.26	16406.37	9449.18
2	115329.59	90484.45	458086.40
3	117558.44	93523.80	324439.35
4	3321.75	22834.33	11526.32
5	3845.27	21514.14	17581.35
6	1448.84	16181.35	9216.63
7	1826.28	14918.43	9290.92

Tabla 4. MSE de los resultados obtenidos por los modelos neuronales NAR, NIO y NARX. Se muestran los resultados promedio para las siete series de datos según el algoritmo de entrenamiento.

Adicionalmente, existe otro parámetro asociado a los modelos neuronales aplicados que es el algoritmo que se utiliza para actualizar los pesos del modelo. El error de salida generado por los modelos neuronales para los siete algoritmos diferentes se muestra en la Tabla 5.

Los algoritmos de entrenamiento que conducen a mejores resultados (menor error) son “Scaled Conjugate Gradient” (6) para NAR y NARX y “Broyden–Fletcher–Goldfarb–Shanno Back-propagation” (7) para NIO. Por otro lado, los algoritmos que conducen a los peores resultados son “Batch Gradient Descent” (2) y Gradient Descent with Momentum (3) para los tres modelos.

El indicador de error por algoritmo de entrenamiento también se muestra en la Figura 3 para las siete series de datos en estudio. Los algoritmos 2 y 3 se excluyen en esta Figura debido a las altas tasas de error que conducen a una mala visualización de las tasas de error asociadas a los algoritmos de mejor rendimiento. De los incluidos en la Figura (1, 4, 5, 6 y 7), se pueden derivar conclusiones similares a las obtenidas de la Tabla 4: los algoritmos 6 y 7 son los que conducen a las tasas de error más pequeñas. Se obtienen índices cercanos, pero ligeramente superiores utilizando el algoritmo 1.




Figura 3. Diagrama de caja que representa el MSE de los resultados obtenidos por los modelos neuronales NAR, NIO y NARX. Los resultados de las siete series de datos se agrupan según el algoritmo de entrenamiento.

Seleccionar la mejor serie temporal para predecir el precio de HRC es uno de los principales objetivos de la presente investigación. Por ello, en la Tabla 5 se muestra el error individual por cada una de las siete series de datos utilizadas.

En los resultados que se muestran en la Tabla 5, no se promedia la medida del error (para todas las combinaciones de parámetros) sino que se muestra el mejor resultado individual (promediado para las diez ejecuciones). El mejor resultado individual se obtiene con la serie de datos 4 en el caso del modelo NARX y se obtiene con la serie de datos 3 en el caso del modelo NIO. Al considerar los modelos neuronales, se puede decir que, para todas las combinaciones de series de datos, NARX supera a NIO en todos los casos.

<i>Input Data Series</i>	<i>NAR</i>	<i>NIO</i>	<i>NARX</i>
Price itself	566.63	-	-
1	-	789.75	460.41
2	-	1150.34	796.86
3	-	664.81	582.63
4	-	1245.19	453.77
1 + 2	-	1378.23	1183.99
1 + 2 + 3	-	1718.82	550.18
1 + 2 + 3 + 4	-	1935.58	520.74

Tabla 5. MSE de los resultados obtenidos por los modelos neuronales NAR, NIO y NARX. Se muestran los mejores resultados individuales (promediados solo para las diez ejecuciones) por serie de datos

Finalmente, los valores MSE obtenidos por los modelos NIO y NARX se muestran en la Figura 4, agrupados por serie de datos. Aunque no es fácil seleccionar visualmente la serie que conduce a mejores resultados generales entre 1, 3, 4, 1+2+3 y 1+2+3+4, se puede decir que las que contienen la serie 2 (2 y 1+2) son las que conducen a mayores tasas de error.




Figura 4. Diagrama de caja que representa el MSE de los resultados obtenidos por los modelos neuronales NIO y NARX. Los resultados de las siete series de datos se agrupan por serie de datos.

Para concluir, los mejores resultados (promedio de diez ejecuciones) hasta el momento se han obtenido al aplicar el modelo NARX. El mejor se ha obtenido al aplicarlo al grupo de conjuntos de datos 4. Además, cabe mencionar que NARX supera claramente a NIO cuando se aplica tanto a las series individuales (1, 2, 3 y 4) como a las combinaciones de ellas (1+2, 1+2+3, 1+2+3+4).

REFERENCIAS

- [1] F. Mehmanpazir, K. Khalili-Damghani, and A. Hafezalkotob, "Dynamic strategic planning: A hybrid approach based on logarithmic regression, system dynamics, Game Theory and Fuzzy Inference System (Case study Steel Industry)," *Resources Policy*, vol. 77, 2022, doi: 10.1016/j.resourpol.2022.102769.
- [2] A. N. Conejo, J. P. Birat, and A. Dutta, "A review of the current environmental challenges of the steel industry and its value chain," *J Environ Manage*, vol. 259, 2020, doi: 10.1016/j.jenvman.2019.109782.

- [3] J. P. Gutierrez and A. C. Vianna, "Price effects of steel commodities on worldwide stock market returns," *North American Journal of Economics and Finance*, vol. 51, no. April, 2020, doi: 10.1016/j.najef.2018.09.007.
- [4] European Commission, "Towards competitive and clean European steel," 2021.
- [5] S. Wu, S. Liu, H. Zong, Y. Sun, and W. Wang, "Research on a Prediction Model and Influencing Factors of Cross-Regional Price Differences of Rebar Spot Based on Long Short-Term Memory Network," *Sustainability*, vol. 15, no. 6, p. 4951, Mar. 2023, doi: 10.3390/su15064951.
- [6] A. G. Malanichev and P. V. Vorobyev, "Forecast of global steel prices," *Stud Russ Econ Dev*, vol. 22, no. 3, pp. 304–311, 2011, doi: 10.1134/S1075700711030105.
- [7] J. P. Gutierrez and A. C. Vianna, "Price effects of steel commodities on worldwide stock market returns," *North American Journal of Economics and Finance*, vol. 51, no. October, 2020, doi: 10.1016/j.najef.2018.09.007.
- [8] S. Pauliuk, T. Wang, and D. B. Müller, "Steel all over the world: Estimating in-use stocks of iron for 200 countries," *Resour Conserv Recycl*, vol. 71, 2013, doi: 10.1016/j.resconrec.2012.11.008.
- [9] D. Panasiyk, B. Laratte, and S. Remy, "Steel Stock Analysis in Europe from 1945 to 2013," *Procedia CIRP*, vol. 48, pp. 348–351, 2016, doi: 10.1016/j.procir.2016.04.084.
- [10] A. O. Adewuyi, B. A. Wahab, and O. S. Adeboye, "Stationarity of prices of precious and industrial metals using recent unit root methods: Implications for markets' efficiency," *Resources Policy*, vol. 65, no. July 2019, 2020, doi: 10.1016/j.resourpol.2019.101560.
- [11] S. J. Terregrossa and U. Şener, "Employing a generalized reduced gradient algorithm method to form combinations of steel price forecasts generated separately by ARIMA-TF and ANN models," *Cogent Economics and Finance*, vol. 11, no. 1, 2023, doi: 10.1080/23322039.2023.2169997.
- [12] S. M. T. U. Raju *et al.*, "An Approach for Demand Forecasting in Steel Industries Using Ensemble Learning," *Complexity*, vol. 2022, p. 9928836, 2022, doi: 10.1155/2022/9928836.
- [13] M. V. Manu, V. Brătăşanu, and I. Vasile, "Challenging the Status Quo: Steel Producer Case Study on the Enterprise Value for M&A," *Management Dynamics in the Knowledge Economy*, vol. 7, no. 2, pp. 207–228, 2019, doi: 10.25019/mdke/7.2.05.
- [14] S.-C. C. Ming-Tao Chou, Ya - Ling Yang, "Review of Economics & Finance A Study of the Dynamic Relationship between Crude Oil Price," *Better Advances Press, Canada in its journal Review of Economics & Finance.*, vol. 2, no. May, 2012.

- [15] P. Rodríguez Liboreiro, "Competencia, rendimientos crecientes y exceso de capacidad: la industria siderúrgica mundial (2000-2014)," *Cuadernos de Economía*, vol. 38, no. 76, 2019, doi: 10.15446/cuad.econ.v38n76.61257.
- [16] P. Zola and M. Carpita, "Forecasting the steel product prices with the arima model," *Statistica e Applicazioni*, vol. 14, no. 1, 2016.
- [17] K. A. Adli, "Forecasting steel prices using ARIMAX model: A case study of Turkey," *The International Journal of Business Management and Technology*, vol. 4, no. 5, pp. 62–68, 2020.
- [18] K. Cetin, S. Aksoy, and I. Iseri, "Steel Price Forecasting Using Long Short-Term Memory Network Model," in *UBMK 2019 - Proceedings, 4th International Conference on Computer Science and Engineering*, 2019. doi: 10.1109/UBMK.2019.8907015.
- [19] S. Karasu, A. Altan, S. Bekiros, and W. Ahmad, "A new forecasting model with wrapper-based feature selection approach using multi-objective optimization technique for chaotic crude oil time series," *Energy*, vol. 212, 2020, doi: 10.1016/j.energy.2020.118750.
- [20] X. Xu and Y. Zhang, "Steel price index forecasting through neural networks: the composite index, long products, flat products, and rolled products," *Mineral Economics*, 2022, doi: 10.1007/s13563-022-00357-9.
- [21] C. Alonso de Armiño, M. Á. Manzanedo, and Á. Herrero, "Analysing the intermeshed patterns of road transportation and macroeconomic indicators through neural and clustering techniques," *Pattern Analysis and Applications*, vol. 23, no. 3, 2020, doi: 10.1007/s10044-020-00872-x.
- [22] M. Yartu, C. Cambra, M. Navarro, C. Rad, Á. Arroyo, and Á. Herrero, "Humidity forecasting in a potato plantation using time-series neural models," *J Comput Sci*, vol. 59, 2022, doi: 10.1016/j.jocs.2021.101547.
- [23] R. Alcalde, D. Urda, C. A. de Armiño, S. García, M. Manzanedo, and Á. Herrero, "Non-linear Neural Models to Predict HRC Steel Price in Spain," in *Lecture Notes in Networks and Systems*, 2023. doi: 10.1007/978-3-031-18050-7_18.
- [24] S. Guo, H. Li, H. An, Q. Sun, X. Hao, and Y. Liu, "Steel product prices transmission activities in the midstream industrial chain and global markets," *Resources Policy*, vol. 60, no. November 2018, pp. 56–71, 2019, doi: 10.1016/j.resourpol.2018.11.014.
- [25] I. J. Leontaritis and S. A. Billings, "Input-output parametric models for non-linear systems Part I: Deterministic non-linear systems," *Int J Control*, vol. 41, no. 2, 1985, doi: 10.1080/0020718508961129

CAPÍTULO IV. DIVERGENCIAS ENTRE LOS ESTADOS MIEMBROS DE LA UNIÓN EUROPEA SOBRE LA SOSTENIBILIDAD DEL TRASPORTE DE MERCANCÍAS POR CARRETERA

Resumen: La Unión Europea es altamente dependiente de la energía. Este trabajo analiza el consumo energético en el sector del transporte, que representa aproximadamente el 30% del consumo energético total. Se prestará especial atención al transporte de mercancías por carretera, que representa el 40% del consumo total de energía del transporte, tratando de contribuir a su racionalización. La relación entre el volumen de transporte de mercancías por carretera (TKM: toneladas-kilómetro) y el producto interior bruto (PIB) cayó en 2010-2022 una media del 17,6% en la UE-27, lo que significa que hubo un crecimiento desacoplado. Alemania es el país con el mayor desacoplamiento, casi el 36%. Por el contrario, en España hay un acoplamiento porque la evolución de TKM y PIB fue casi idéntica. El trabajo propone posibles factores relevantes en la actividad de transporte de mercancías por carretera que puedan justificar las discrepancias de valores entre los países miembros de la UE, mostrando los impactos positivos y negativos de las diferentes variables estudiadas. Además, se aplica el modelo SARIMA para predecir la evolución de indicadores relevantes del transporte por carretera en diferentes países.

Palabras clave: transporte de mercancías por carretera; consumo energético; economía; proceso de desacoplamiento; Unión Europea.

1. Introducción

Desde la antigüedad existe una importante relación entre la actividad de transporte y la economía, dado que muchas civilizaciones basaron su capacidad y prosperidad económica en el desarrollo de infraestructuras de transporte. La primera aproximación científica relevante para estudiar esta relación se desarrolló en el siglo XX con el diseño de un modelo de la actividad de transporte [1], que permitió establecer una conexión directa entre la demanda de transporte y el grado de actividad económica.

Estos estudios se basaron en investigaciones previas sobre la modelización de la demanda de transporte puro, sobre las características de la oferta [2], así como en estudios comparativos de la evolución de la demanda de transporte de mercancías por carretera y ferrocarril [3]. Pronto se estudió la relación entre la actividad de transporte y los llamados flujos input-output que implican el intercambio de bienes entre las diferentes actividades económicas que conforman el PIB [4,5].

El interés por explorar la relación inversa, que vincula el producto interior bruto (PIB) con la actividad de transporte, es cada vez mayor, ya que los analistas económicos quieren obtener lo que se conoce como “indicadores económicos adelantados”, que serán de gran utilidad en las decisiones y políticas empresariales. En este sentido, la Unión Europea ha impulsado el desarrollo de un modelo de evaluación de políticas de transporte denominado HIGH-TOOL, que permite identificar y evaluar los impactos de sus políticas sobre el transporte, el medio ambiente y la economía. Su principal innovación radica en la integración de otros modelos y en el hecho de que se trata de una herramienta libre y de código abierto [6]. Estas herramientas no permitían evaluar y predecir tendencias generales en algunas características relevantes en el desarrollo de la actividad de transporte y además han quedado como un proyecto anticuado, por lo que no fueron válidas para este artículo

Recientemente, diferentes estudios han examinado la relación entre el PIB y el índice de desempeño logístico (LPI), un indicador sintético definido por el Banco Mundial para comprender la competitividad y calidad de los servicios logísticos. Este análisis se realiza sobre el comercio internacional de las naciones en cada continente y a nivel mundial. Sus hallazgos revelan que el LPI se correlaciona positivamente con las exportaciones netas a nivel mundial [7,8].

El vínculo entre la evolución del PIB y la actividad de transporte de mercancías es directo y responde a modelos y variables específicos [9]. Por ejemplo, en EE. UU., existe una fuerte relación entre el crecimiento económico y el aumento de la actividad de transporte aéreo de mercancías y pasajeros [10].

Por otro lado, en algunos países, el transporte ha crecido más lentamente que el PIB, lo que los autores definen como “disociación”, lo que indica un debilitamiento del vínculo transporte-economía. En otros, el transporte ha disminuido en el contexto de tasas de crecimiento económico favorables, manifestadas como un “fuerte o absoluto desacoplamiento”; por ello, autores como Ballinghan et al. [11] llegan a sugerir que el vínculo se ha roto. Algunos investigadores también observan un desacoplamiento más sustancial en los países “periféricos” de la UE y una correlación más fuerte en los países de Europa central [12,13].

En investigaciones posteriores, se ha producido un desacoplamiento significativo de la actividad de transporte de mercancías y la economía en Europa, lo que sugiere que un factor esencial en este cambio puede haber sido la mayor eficiencia del transporte [14,15]. Tight et al. [16] concluye que la evolución de la relación entre la actividad de transporte y la economía se está moviendo hacia una mayor sostenibilidad. Otros estudios en dominios específicos llevan a conclusiones equivalentes [17–19].

Se desarrollan dos nuevos conceptos: (1) inmaterialización, referida a la reducción de la intensidad del transporte y de la actividad económica, y (2) desmaterialización,

correspondiente a la reducción de emisiones y necesidades energéticas, estrechamente vinculada al proceso de descarbonización. Estudios como los de Andreoni y Calmarini [20] no dudan en proclamar un fuerte desacoplamiento de las emisiones ambientales de la actividad económica, a pesar de la difícil situación económica.

Savy y Burnham [21] revisaron las realidades y cifras globales del transporte, apuntando hacia nuevos marcos contractuales más complejos y sofisticados en contraposición a la visión puramente bipolar de productores y transportistas [21]. Además, Liimatainen y Pollänen [22] analizaron cómo los diferentes sectores productivos están más o menos desacoplados de la actividad del transporte. Stahel [23] vincula los efectos del desacoplamiento económico con la aparición de tendencias de economía circular.

Desde 1995 a 2012, Botzoris et al. han presentado un amplio estudio sobre el acoplamiento y desacoplamiento en la UE, destacando la crisis de 2008. Por su parte, Alises y Vassallo [25] actualizaron el estudio del desacoplamiento de la actividad de transporte respecto a las tablas input-output del PIB en España, lo que confirma la tendencia al desacoplamiento. Loo y Banister [26] profundizaron en los conceptos de inmaterialización y desmaterialización para demostrar, como ya se había señalado en el ámbito de la investigación, que los resultados indican un menor desacoplamiento en los países periféricos que en los centrales.

Loo y Banister [26] propusieron una nueva perspectiva, en la que el precio del petróleo podría haber producido efectos diferentes sobre la demanda de transporte de mercancías a lo largo de las cadenas de suministro. En áreas geográficas ligadas al consumo, como la UE y, en general, en los países desarrollados, los precios del petróleo pueden limitar la actividad de transporte y producir el desacoplamiento de sus economías mencionado anteriormente. En otros países ligados a la producción de bienes, como el Sudeste Asiático, el desacoplamiento es prácticamente inexistente. En este sentido, Kos-Labedowicz y Urbanck [27] concluyen, a partir de resultados parciales equivalentes, que la explicación puede encontrarse en las diferentes bases tecnológicas de las naciones y que la aplicación de nuevas tecnologías en el proceso de transporte conduce al desacoplamiento con mayor intensidad, aconsejando una apuesta decidida por ellas.

Investigaciones recientes han analizado las relaciones de acoplamiento y desacoplamiento entre el consumo energético relacionado con el transporte y el PIB, encontrando que la mayoría de los países han superado el umbral de acoplamiento tras la última crisis y están experimentando un modo de desacoplamiento. Esta situación representa un desafío político e institucional, ya que el desacoplamiento observado debería abandonarse para fortalecer y promover una movilidad verde y eficiente [28].

A diferencia de lo que se lleva a cabo en este artículo, no se encontraron trabajos que centraran sus estudios en un número suficientemente grande de países de la UE o que analizaran, en detalle, parámetros específicos del desarrollo de la actividad de transporte de mercancías por carretera (TKM, Toneladas, VKM, VKM vacío, Viajes, Viajes vacíos, PIB, Uso general de energía y Transporte de energía por carretera).

Datos de Eurostat [29] sobre consumo energético en la UE desde 2010 a 2022, indican en primer lugar, que la producción de energía en la UE-27 se ha mantenido en alrededor de 250 M de toneladas equivalentes de petróleo (tep) durante la última década, con la producción más baja de toda la década en 2022, probablemente debido a la reducción de la actividad resultante de la pandemia.

En 2010, la UE-27 consumió 973 Mtep, reduciéndose a 902 Mtep en 2022, lo que supone una disminución de casi el 7% del consumo total de energía. Esta disminución también se observa en los países con mayor consumo, como Alemania, Francia, Italia y España. La UE-27 es muy deficitaria en energía y, por tanto, tiene que importar muchos productos energéticos.

Analizando el consumo total de energía en los principales países consumidores de la UE, Alemania se sitúa en primer lugar, seguida de Francia e Italia, y España en cuarta posición.

Analizando el consumo por sectores en 2010-2022 (Figura 1), se puede observar que el sector líder es el transporte, con un 29,67% del total, seguido de los hogares con un 27,39% y la industria con un 25,63%.

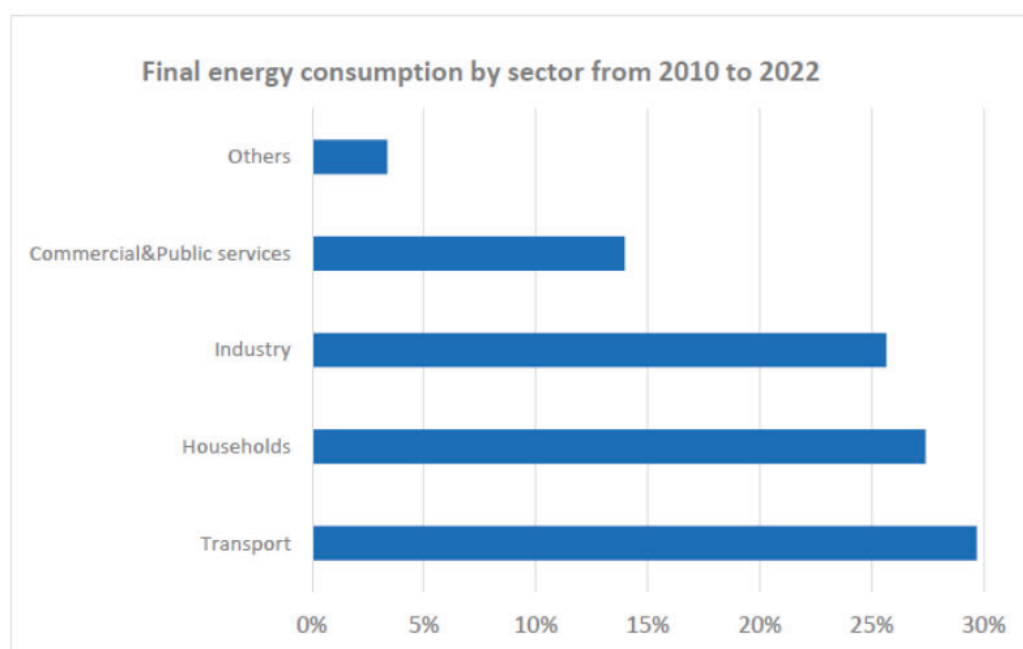


Figura 1. Consumo de energía por sector en la UE-27, período 2010-2022 Eurostat [29].

Smokers et al. [30] encontraron que el sector del transporte debe reducir sus emisiones en un 50% en comparación con sus niveles de 1990 para ser sostenible. Este artículo estudia las relaciones entre la economía y la actividad de transporte y la actividad de transporte y el consumo de energía, con el fin de determinar el acoplamiento de estos elementos y determinar si la tendencia en el consumo de energía del transporte es insostenible o no por sí misma y por las emisiones que genera.

Abid y Sebri [31] se centraron en países específicos, e investigaron la relación causal entre el consumo de energía y el desempeño económico de los sectores industrial, de transporte y residencial. Tvaronavičienė [32] analizó la eficiencia energética en el sector del transporte de tres países europeos, considerando las implicaciones políticas, la gestión de recursos y la eficiencia de los recursos energéticos convencionales. Aza y Escribano [33] indicaron que, a pesar del crecimiento experimentado por los servicios de transporte en España y Europa, existe una clara tendencia a la baja en la intensidad de los servicios de transporte respecto al PIB (desacoplamiento creciente).

Bernali y Feki [34] encontraron vínculos dinámicos irrefutables entre transporte, consumo, economía y emisiones de gases en un período de estudio de 34 años de desarrollo en Túnez. En este sentido, se puede observar que las medidas adoptadas en diferentes entornos políticos y económicos arrojan resultados notablemente diferentes en las relaciones entre economía, actividad de transporte y emisiones, como señalaron Shafique et al. [35]. Además, Sun et al. [36] también sugirieron la contribución decisiva de las tecnologías en una reducción proporcional de las emisiones en la actividad de transporte. Touratier-Muller y Jaussaud [37] dieron un paso más, recomendando que los estados deberían alentar a las empresas a contratar sus actividades con transportistas que mantengan ciertas características de emisión en sus flotas de vehículos, por ejemplo, una cierta mezcla de vehículos Euro V y Euro VI. Esta hipótesis parece estar apoyada por los resultados del estudio de Pollänen et al. [38], que muestran que ha habido muy poca conciencia y poca acción tomada por el sector del transporte de mercancías por carretera en los últimos 12 años.

Por otro lado, las preocupaciones sobre las emisiones marcan gran parte de la investigación. Así, Achour y Belloumi [39] investigaron las relaciones causales entre la infraestructura de transporte, el valor añadido del transporte, la formación bruta de capital y el consumo de energía del transporte, incluidas las emisiones de CO₂. Saidi et al. [40] analizaron las mismas relaciones causales y sus resultados muestran la causalidad unidireccional a largo plazo del valor añadido del transporte, el consumo de energía relacionado con el transporte por carretera, las emisiones de CO₂ y la formación bruta de capital. Mohsin et al. [41] consideran el problema de las emisiones, indicando que el sector del transporte consume el 25% de la energía mundial con el 23% de las emisiones mundiales. Una característica clave en esta relación será la

adecuada utilización u ocupación de las capacidades de transporte de los medios involucrados [42].

Osorio-Tejada et al. [43] incorporó variables relevantes a tener en cuenta en cuanto a consumos y emisiones de la flota de transporte, que son aquellas relacionadas con las condiciones orográficas y que pueden encerrar variaciones de hasta el 145%.

2. Investigación

Esta investigación aborda dos líneas diferenciadas entre la escasa investigación específica existente que analiza el desacoplamiento entre economía y consumo energético. En primer lugar, el mencionado por Profillidis et al. [28] certifica la existencia de este desacoplamiento, sin profundizar en el análisis de las causas ni señalar el reto que es necesario afrontar para mantenerlo. En segundo lugar, trabajos más recientes se centran en analizar la intensidad del transporte y sus efectos sobre la economía, estudiando los resultados de las actividades sociales y económicas y cómo modelizar la intensidad del transporte de las economías nacionales en los países europeos.

Además de la conexión ya destacada entre economía y transporte, hay que considerar que esta conexión es especialmente marcada para la sostenibilidad cuando se trata del transporte de mercancías por carretera.

La mayor parte de los volúmenes de transporte de mercancías se realizan por carretera. La demanda total de transporte interior de mercancías (es decir, por carretera, ferrocarril, vías navegables interiores y oleoductos) aumentó un 22% entre 2000 y 2019. En 2019, se transportaron 2411 billones de toneladas-kilómetro (TKM, una medida de la actividad de transporte de mercancías que explicaremos a continuación en la primera sección de este punto) por estos modos. La participación del transporte por carretera en esta demanda creció del 68% en 2000 al 73% en 2019 [44].

2.1. Metodología y estructura de la investigación

La metodología de esta investigación comienza realizando un análisis para diferentes territorios de la UE: (i) consumo energético versus evolución económica, (ii) evolución de la actividad de transporte de mercancías por carretera versus evolución económica, y (iii) estudio detallado de la divergencia territorial de algunos de sus indicadores específicos vinculados a la eficiencia en esta actividad de transporte de mercancías por carretera. Añadimos a la metodología el desarrollo de un modelo predictivo de la evolución de estos indicadores específicos.

Todos los datos utilizados fueron obtenidos de Eurostat [29], así como los ya utilizados en el ámbito energético y económico. En este sentido, ahora es necesario aclarar algunas cuestiones específicas que utilizaremos en nuestra investigación. Se trata de datos relacionados con el transporte de mercancías por carretera con el siguiente significado:

- La tonelada-kilómetro (tkm o TKM) es una unidad de medida del transporte de mercancías que representa el transporte de una tonelada de mercancías por un modo de transporte determinado (carretera). Es la principal medida del rendimiento del transporte, ya que combina sus dos dimensiones principales, masa transportada y distancia de transporte, para significar la energía consumida.
- La tonelada (t o T) es el peso transportado y km es la distancia recorrida en kilómetros por el desplazamiento del vehículo de transporte y puede ser una distancia recorrida con carga o sin carga.
- El vehículo-kilómetro (vkm o VKM) es la distancia recorrida en kilómetros para un viaje del vehículo de transporte y puede ser una distancia con carga o sin carga.
- Los desplazamientos son el número de viajes que realiza un vehículo de transporte y pueden ser viajes cargados o vacíos.

Al comparar TKM con las dos magnitudes VKM y desplazamientos, podemos analizar la mejora de la eficiencia y sostenibilidad de este modo de transporte analizando las distancias y los desplazamientos realizados sin carga de mercancías en cada área geográfica y su evolución en el tiempo.

2.2. Datos y análisis

Para este estudio se han utilizado datos de Eurostat [29].

2.2.1. Desacoplamiento de la economía y el consumo energético

Examinando la evolución global del consumo energético en la UE en relación con el PIB (Figura 2), la UE-27 logró reducciones proporcionales significativas en su consumo energético en relación con su PIB.

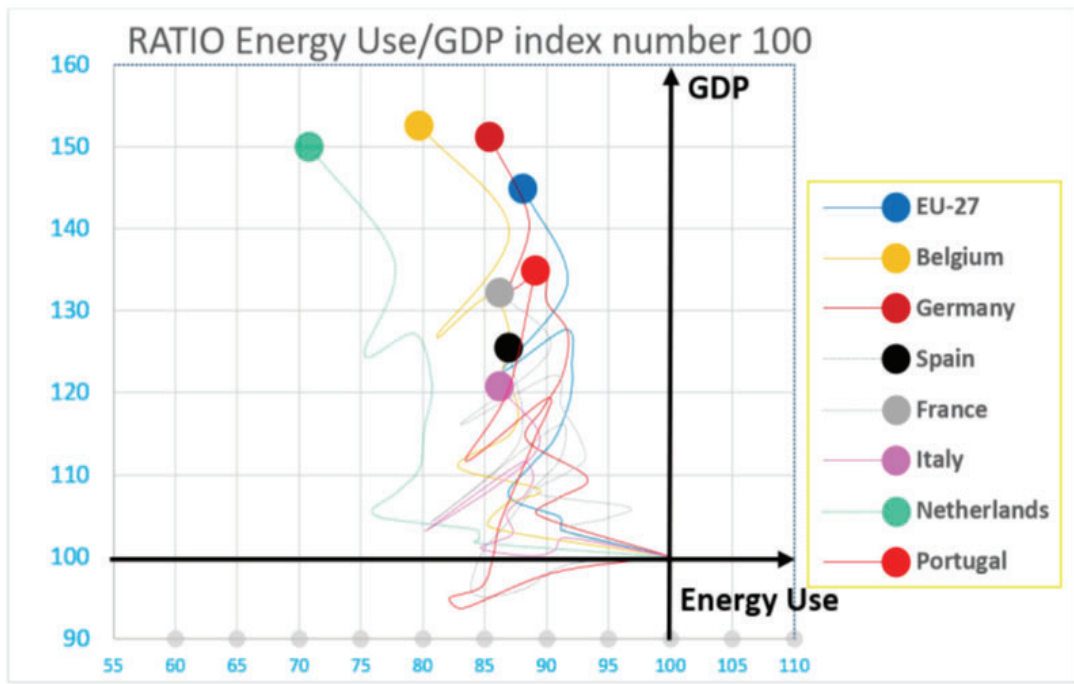


Figura 2. Consumo de energía vs. PIB. Índice 100 en 2010, de 2010 a 2022 Eurostat [29].

Esta tendencia fue general en todos los países de la UE, con solo desajustes menores que cabe destacar, con un mayor desacoplamiento en los Países Bajos, Bélgica y Alemania, un desacoplamiento medio en Portugal y Francia, y un desacoplamiento menor en España e Italia.

2.2.2. Desacoplamiento de la economía y el consumo de energía en el transporte

Al examinar los datos desde la misma perspectiva del consumo de energía en el transporte (Figura 3), también se encontraron diferencias entre países. Nuestros clústeres anteriores eran alargados, mostrando aspectos relevantes significativos, como el fuerte desacoplamiento energético del transporte holandés y el aumento de la tasa de consumo de transporte en Francia.




Figura 3. Consumo energético en el transporte respecto al PIB. Índice 100 en 2010, de 2010 a 2022. Eurostat [29].

2.2.3. Desacoplamiento de la economía y el consumo energético en el transporte por carretera

Por último, esta investigación se amplió al transporte de mercancías por carretera, que, como se ha mencionado anteriormente, representa un volumen decisivo de la actividad de transporte en Europa. No se disponía de datos estadísticos desagregados sobre qué tipo de consumo pertenecía al transporte de mercancías y de pasajeros en servicio público y en uso privado, por lo que tuvimos que estudiar su magnitud general. Analizando la evolución de esta forma de consumo energético (Figura 4), obtuvimos resultados prácticamente idénticos a los de la Figura 3.

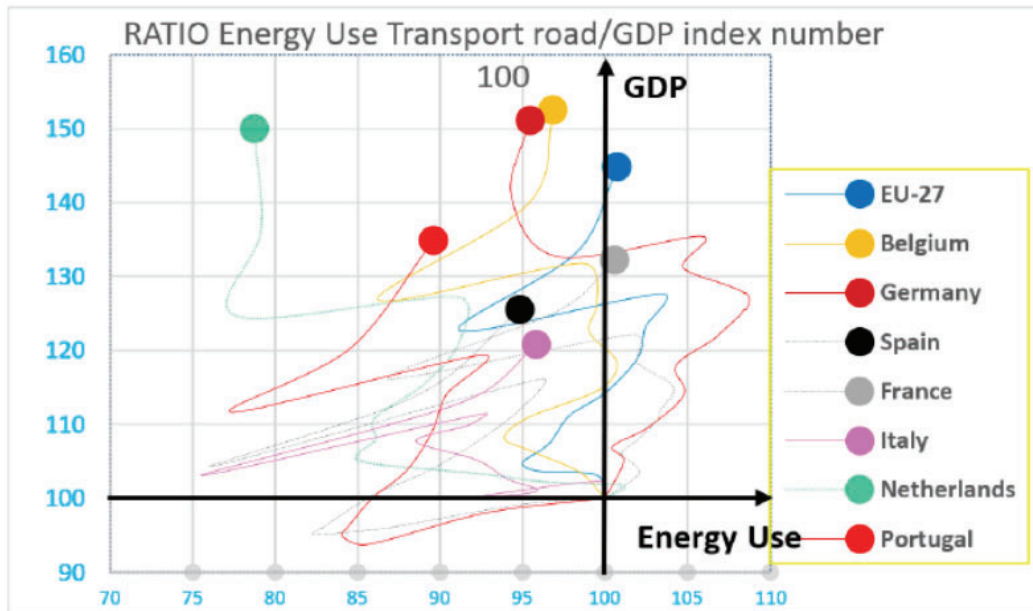


Figura 4. Consumo energético en el transporte por carretera respecto al PIB. Índice 100 en 2010. Eurostat [29].

Se ha vinculado la economía a la actividad de transporte y viceversa. La evidencia sugiere que se estaba produciendo un cierto desacoplamiento en este vínculo, y (quizás como consecuencia) también había un desacoplamiento de estas magnitudes y el consumo energético. Sin embargo, también estaba claro que no se seguía la relación exacta en todos los países y que había diferencias significativas entre ellos. El carácter periférico de algunos países ofrecería explicaciones científicas para esta tendencia, pero bien podrían deberse a la influencia de otras variables menos evidentes. Debido a esta posibilidad, se consideró necesario profundizar en el conocimiento de las magnitudes que podrían influir en este desacoplamiento.

En este sentido, Aza y Escribano [33] desarrollaron un estudio centrado en el sector agregado de servicios de transporte y almacenamiento. Encontraron que la medida de la participación del crecimiento en este sector derivaba de elementos y aspectos de gran relevancia, como el uso e inversión en tecnologías de la información y la comunicación, el capital humano, el progreso tecnológico y la productividad total de los factores. También mencionaron otros efectos económicos que el modelo de contabilidad del crecimiento no captó pero que sin embargo fueron significativos.

2.2.4. Desacoplamiento de la economía y el consumo energético en el transporte de mercancías por carretera

Este trabajo se centrará en la actividad de transporte de mercancías por carretera en la UE y algunos de sus países, como España. Considerando que el TKM es una medida de

la actividad de transporte de mercancías por carretera y el PIB es una medida de la actividad económica desarrollada, para ello, el punto de partida será el ratio entre el TKM producido y el volumen del PIB (Figura 5).

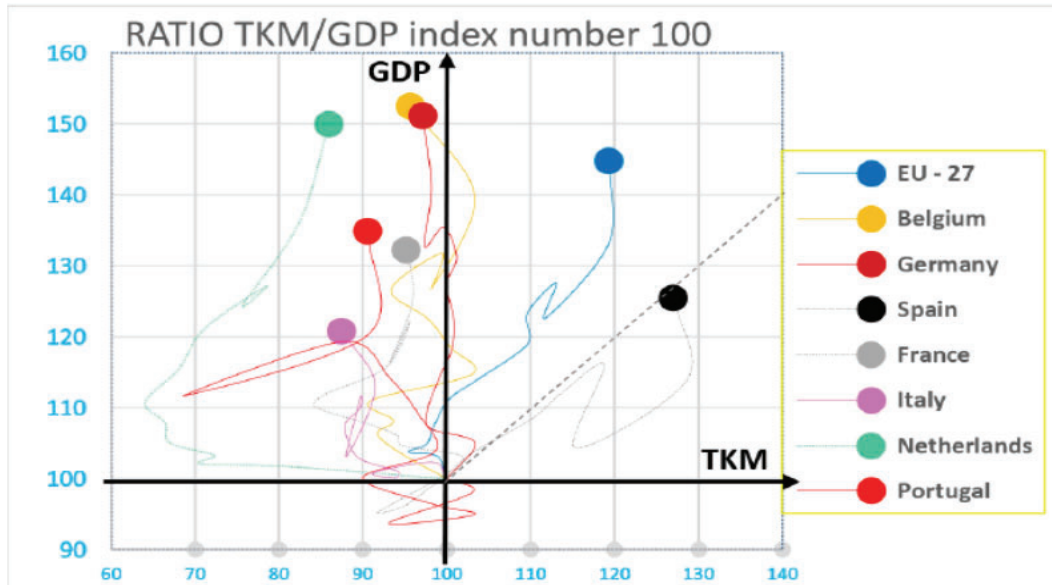


Figura 5. Volumen de transporte de mercancías (TKM) vs. PIB. Índice 100 en 2010 Eurostat [29].

El estudio reveló algunos aspectos interesantes: (1) La mayoría de los ratios mostraron una disminución progresiva. (2) Sin embargo, algunos países aumentaron el ratio hacia mediados de la década. (3) España parecía ser la excepción, habiendo aumentado finalmente su ratio. (4) La UE se encontraba en una senda intermedia en su conjunto y en un nivel mantenido con pequeñas fluctuaciones a lo largo del período.

Desacoplamiento o reacoplamiento no podía ni debía considerarse una pérdida o aumento en la relación sino más bien un cambio en la forma en que se establecía. Este cambio podría haberse debido a múltiples factores, incluido el hecho de que la economía se estaba vinculando cada vez más a los servicios y a la gestión realizada por plataformas virtuales. Por el contrario, la economía se apoyaba en un aumento en la distribución de bienes y/o un cambio en el patrón de distribución de bienes, por ejemplo, transportando más peso en distancias más largas.

El desacoplamiento de la actividad de transporte de la economía es un aspecto positivo para la sostenibilidad porque permite reducir el impacto ambiental así como los costos económicos. Más concretamente, la razón es que consigue una menor sobrecarga de las infraestructuras; reducciones del impacto ambiental de sus emisiones; reducciones de los daños sociales, especialmente los accidentes de tráfico; y reducciones de su consumo energético, ya que la pregunta relevante aquí es si existe

un desacoplamiento deseable o un reacoplamiento indeseable entre el consumo energético del transporte y el crecimiento económico.

La investigación de Andrés y Padilla [45] detectó una mejora en la intensidad energética del transporte de mercancías por carretera. Atribuyeron este efecto al progreso tecnológico de los equipos de transporte, sino también a lo que percibían como una mejora relativa de la densidad de cargas; es decir, la capacidad de los vehículos parecía estar mejor aprovechada, simplemente apuntando en esta dirección sin el contraste adecuado.

2.3. Una selección de países representativos de la UE

La medida más completa de la actividad de transporte de mercancías por carretera son las tkm generadas, como ya hemos mencionado. Podemos observar la magnitud de esta medida desde 2010 hasta 2022 en la Tabla 1. Por tanto, el primer paso es analizar la actividad de este transporte con la variable que mejor representa su actividad global, que no es otra que las TKM realizadas.

Country 1	Millions of TKM (2010–2022)	Ranking
EurUnion 27 (from 2020)	22,173,377	
Germany	4,048,051	1
Spain	2,929,703	2
France	2,217,939	3
Netherlands	1,729,042	4
Italy	913,865	5
Belgium	441,855	6
Portugal	429,376	7

Tabla 1. Millones de TKM producidos por los territorios de la UE de 2010 a 2022.

En la Tabla 1 se observa que los países con mayor contribución a la producción de TKM son Alemania, España y Francia, que en conjunto representan el 41,5% de la magnitud total en la UE. Además, si volvemos a observar la Figura 5, vemos que estos tres países lideran precisamente tres tendencias generales respecto a los territorios estudiados:

1. Alemania, al igual que Bélgica y los Países Bajos, experimentó un fuerte crecimiento de la actividad económica y un claro desacoplamiento de su actividad de transporte, que creció ligeramente.
2. Francia, al igual que Portugal e Italia, experimentó un crecimiento medio de su economía y también mantuvo un desacoplamiento con su actividad de transporte, que disminuyó ligeramente.
3. España (en este caso, en modo stand-alone, autónoma), en cambio, mantuvo un crecimiento medio de su economía, pero no experimentó un

desacoplamiento en la evolución de su actividad de transporte, al contrario, ya que aumentó más que proporcionalmente a su actividad económica, lo que podemos ver claramente en esta Figura si trazamos un eje de 45 grados en el cuadrante superior derecho.

Por ello, y con fines de clarificación, centraremos en adelante nuestros estudios en estos países, junto con la evolución general de la UE, para analizar magnitudes específicas del desempeño del transporte de mercancías por carretera.

2.3.1. Toneladas Transportadas por Carretera vs. TKM para Países Seleccionados

Un indicador parcial del desarrollo del transporte de mercancías por carretera es la cantidad de masa transportada. Para analizarla, examinaremos la evolución de Toneladas transportadas vs. TKM, con base en lo realizado en la Sección 2.2.4 con el PIB vs. TKM, en la evolución de su índice, basado en un incremento del 100 por ciento sobre los datos del año inicial de la serie en 2010 (Figura 6).

Si bien la evolución de la masa transportada vs. las TKM ejecutadas desde 2010 a 2022 son variables relacionadas, permiten analizar diferencias en el comportamiento de cada país, entre masa y distancia transportada. Alemania ha experimentado un aumento moderado de la masa transportada, frente a la importante reducción en Francia y el mantenimiento en España.

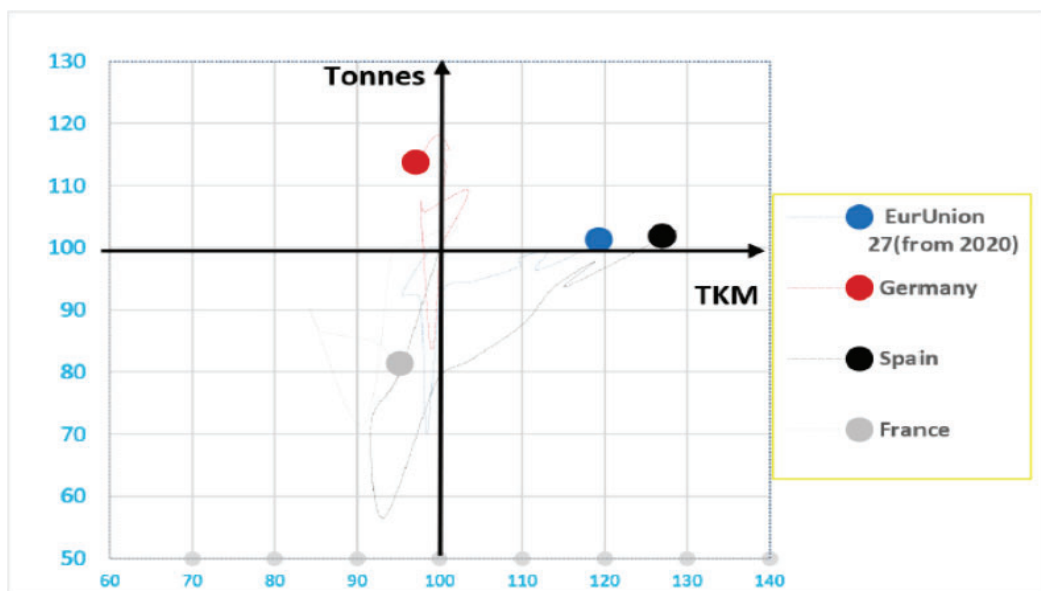


Figura 6. Toneladas transportadas vs. volumen de transporte de mercancías (TKM). Índice 100 en 2010 Eurostat [29].

2.3.2. Distancias recorridas VKM vs. TKM para países seleccionados

A continuación, estudiamos la relación entre la distancia recorrida por viaje (vkm) y las TKM, considerando su evolución, siendo el valor 100 el de 2010.

En este caso, la evolución de la distancia recorrida vs. las TKM ejecutadas es comparable a analizar la evolución de la masa transportada. De la Figura 7 se puede concluir que Alemania mantuvo muy constante la medida de sus distancias de transporte, Francia las redujo ligeramente y España, sin embargo, experimentó una notable tendencia a aumentarlas.




Figura 7. VKM vs. Volumen de transporte de mercancías (TKM). Índice 100 en 2010 Eurostat [29]

2.3.3. Viajes vs. TKM para Países Seleccionados

La siguiente medida parcial del desarrollo del transporte de mercancías por carretera es el número de viajes o desplazamientos realizados transportando mercancías. Para estudiarlo, una vez más, nos centramos en comparar la evolución de su índice 100 de 2010 frente al del TKM.

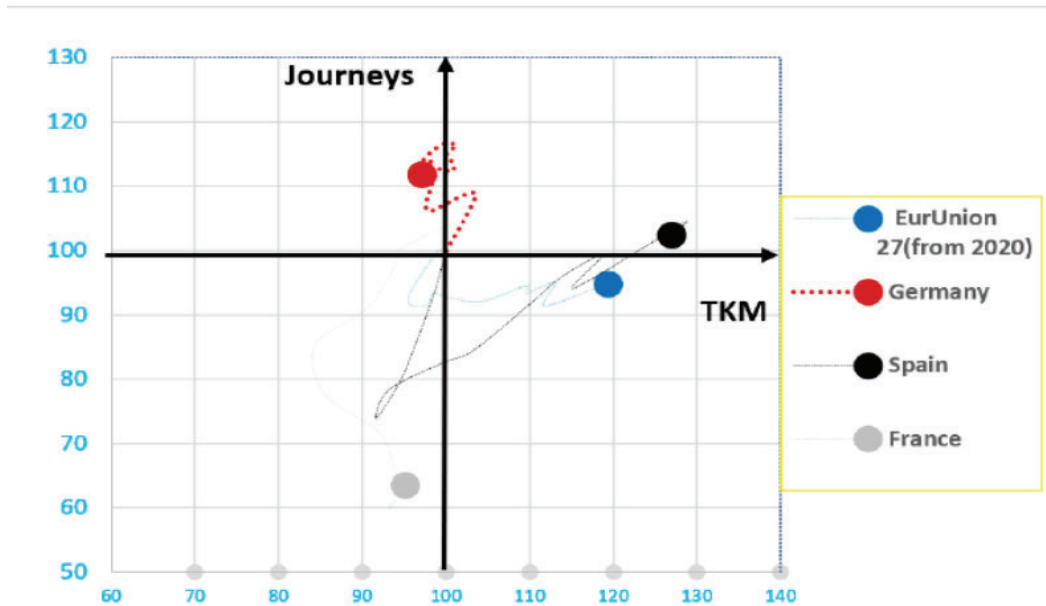


Figura 8. Viajes vs. volumen de transporte de mercancías (TKM). Índice 100 en 2010 Eurostat [29].

De la Figura 8, se puede concluir que: Alemania tuvo una ligera tendencia al aumento de sus desplazamientos, frente a la drástica reducción en Francia y el mantenimiento en España.

2.3.4. Distancias recorridas en vacío frente a TKM para países seleccionados

Una medida del desarrollo del transporte de mercancías por carretera son los movimientos de vehículos sin carga, un indicador evidente de desperdicio.

En la Figura 9, se puede ver que solo Francia ha reducido el transporte en vacío y el volumen de transporte desde 2010, mientras que tanto España como los miembros de la UE han aumentado el transporte en vacío (mayor número de vehículos y/o mayor distancia) y ha aumentado el volumen de transporte (mayores toneladas transportadas y/o mayor distancia). En el caso de Alemania, el número de transportes en vacío también aumenta, mientras que reduce el volumen de transporte en casi el mismo porcentaje que Francia.

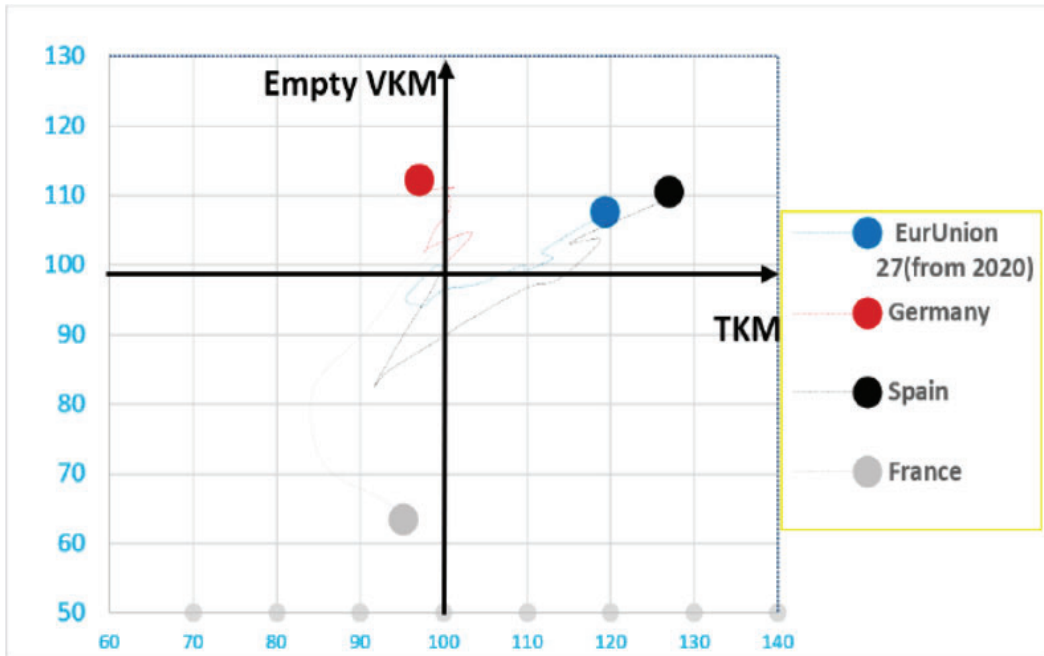


Figura 9. Vkm vacío vs. volumen de transporte de mercancías (TKM). Índice 100 en Eurostat 2010 [29].

2.4. Viajes sin carga vs. TKM para países seleccionados

Otra medida que también es un indicador significativo de desperdicio para el desarrollo del transporte de mercancías por carretera es el transporte de vehículos sin carga.

De la Figura 10, se puede concluir que solo Alemania empeoró en la tendencia de este indicador, y mientras que España lo redujo ligeramente y Francia obtuvo resultados extremadamente positivos en la reducción del mismo.

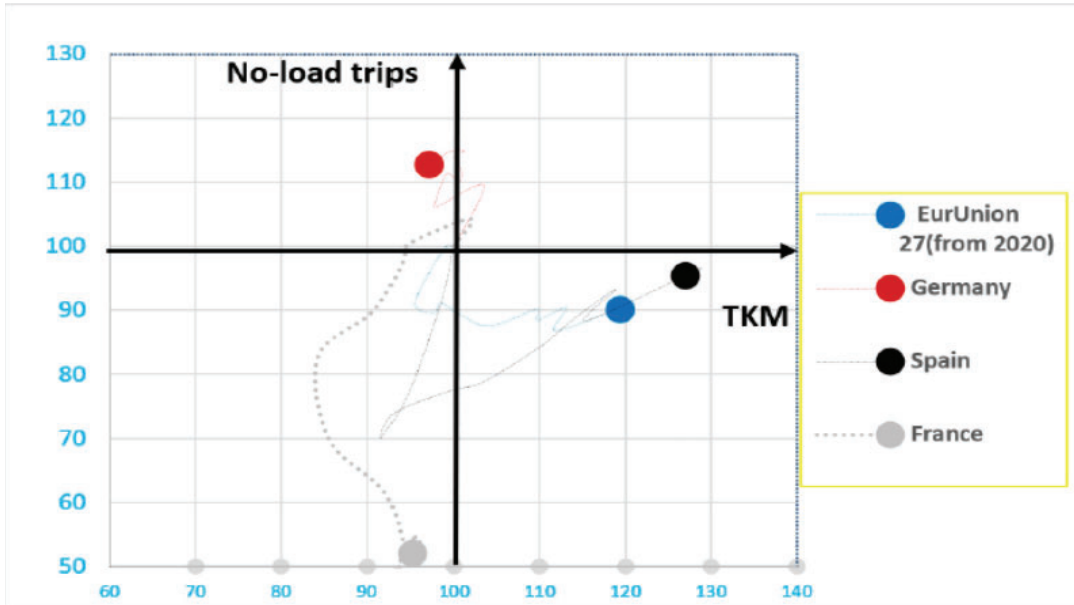


Figura 10. Viajes sin carga vs. volumen de transporte de mercancías (TKM). Índice 100 en 2010 Eurostat [29].

3. Análisis de tendencias

Al finalizar este trabajo, se ha utilizado un conjunto de datos temporales, que abarcan datos sobre kilómetros recorridos tanto con cargas vacías como con cargas, así como TKM.

3.1. Configuración experimental

Los años del conjunto de datos van desde 2010 a 2022 (inclusive), abarcando 13 años, con 52 valores trimestrales para la serie de kilómetros totales. Debido a que las otras dos series no están originalmente en formato trimestral, se han ponderado anualmente. Por ello, se ha realizado una ponderación trimestral en función de la relación anual, tal y como se demuestra en las siguientes Tablas 2 y 3. Para el modelo SARIMA se utilizan los datos hasta 2020 (antes del impacto de la COVID) y los datos de 2021 y 2022 para validar el modelo.

	Annual	Q1	Q2	Q3	Q4
Total km	12,000	4000	2000	3500	2500
Full km	9000				
Empty km	3000				

Tabla 2. Ejemplo de datos originales.

	Annual	Q1	Q2	Q3	Q4
Total km	12,000	4000	2000	3500	2500
Full km	9000	3000	1500	2625	1875
Empty km	3000	1000	500	875	625

Tabla 3. Ejemplo de datos relativos.

La división elegida destina 39 trimestres a formación y 13 trimestres a pruebas, lo que se traduce en un 75% y un 25%, respectivamente. Por tanto, para formación, disponemos de datos desde 2010 hasta septiembre de 2019, y para pruebas, disponemos de datos desde diciembre de 2019 hasta diciembre de 2022.

3.2. Diseño experimental

El presente estudio se centra en comprender de forma exhaustiva dos características del conjunto de datos. En primer lugar, examina la evolución de las TKM (toneladas-kilómetro) en Alemania, España y Francia. En segundo lugar, analiza la relación entre los kilómetros recorridos en vacío y los kilómetros recorridos con carga en estos mismos países, respaldados por los resultados de la UE.

Para realizar un análisis de series temporales, se empleó el bien establecido modelo Seasonal AutoRegressive Integrated Moving Average (SARIMA) [46]. En este reconocido modelo estadístico, es imprescindible comprender los parámetros p , d y q , donde p denota el orden del componente autorregresivo, d significa el grado de diferenciación en el modelo y q representa el tamaño de la media móvil.

Para estandarizar el modelo, se utilizaron como referencias la serie TKM de la UE y la serie de kilómetros vacíos y cargados dentro de la UE.

Se pueden utilizar varias pruebas para determinar estos parámetros, como la prueba Dickey-Fuller aumentada [47] para d . Esta prueba establece un valor p umbral de 0,05 para rechazar la hipótesis nula y, dependiendo del grado de diferenciación requerido para alcanzar este valor, se establece como el valor para d . En el estudio actual, como se muestra en el gráfico inferior, se obtuvo un grado de 2 (Figura 11).




Figura 11. Serie original.

El valor p de la serie original fue 0,96382, en la diferenciación de orden 1 el valor p fue 0,42203 y, finalmente, en la diferenciación de orden 2 el valor p fue 0,00053.

Con base en la función de autocorrelación (ACF) y la función de autocorrelación parcial (PACF), se ha determinado que los valores de q y p son ambos 1.

En este estudio, se utilizaron los paquetes de Python statsmodels <https://www.statsmodels.org/> (consultado el: 12 de julio de 2024) y skforecast <https://skforecast.org/> (consultado el: 12 de julio de 2024), ambos ampliamente reconocidos por su utilidad. Los resultados que arrojan, por ejemplo, en EU TKM son los que se muestran en la Figura 12.

Los resultados obtenidos de las ejecuciones de TKM se muestran en la Tabla 4. Aquí, es evidente que la biblioteca statsmodels proporciona resultados superiores en los primeros casos, mientras que en los otros dos obtiene los mismos resultados; por lo tanto, se utilizará más adelante para fines de pronóstico.

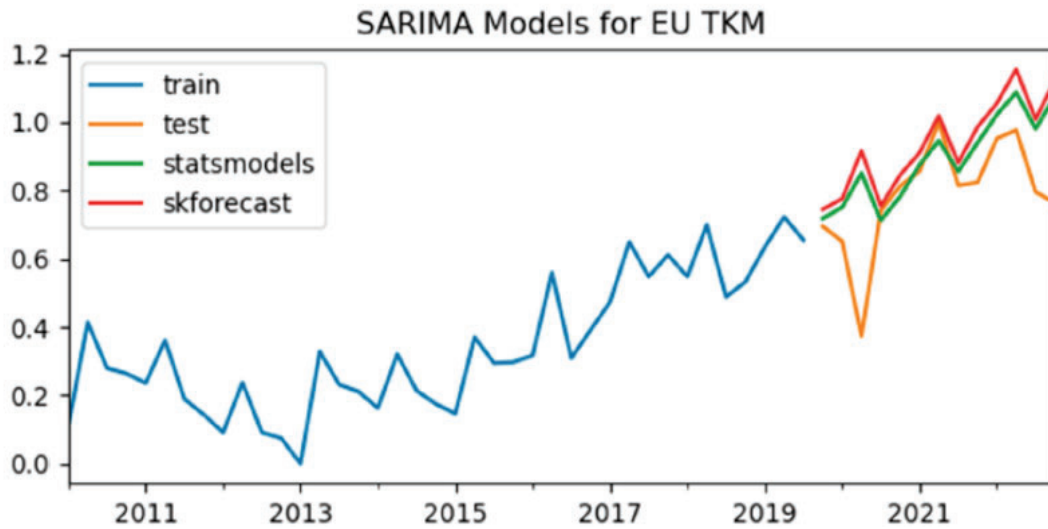


Figura 12. Modelos SARIMA para EU TKM entrenados con datos hasta 2020 (pre-COVID) y probados con datos post-COVID.

	EU TKM		EU VKM Empty		EU VKM Full	
	MSE	MAE	MSE	MAE	MSE	MAE
statsmodel	0.0313	0.1204	0.0314	0.1474	0.0202	0.0913
skforecast	0.0434	0.1475	0.0314	0.1474	0.0202	0.0913

Tabla 4. Resultados obtenidos.

3.3. Previsión

En la sección de previsión, nos hemos basado en la configuración mencionada anteriormente. Además, se ha empleado la biblioteca statsmodels para optimizar aún más estos resultados.

La Figura 13 ilustra los resultados obtenidos por SARIMA. En este gráfico, se ha representado la relación entre kilómetros vacíos y kilómetros cargados para cada país. Las líneas continuas representan la serie existente real, mientras que las líneas discontinuas representan la serie prevista.




Figura 13. Previsión del ratio kilómetros vacío/kilómetros llenos—SARIMA.

A pesar de la presión que supone el aumento de los precios de los combustibles, que está obligando a los transportistas a reducir su nivel de “kilómetros muertos”, es difícil seguir el ritmo del tirón de la contratación electrónica, por lo que la previsión es que el transporte en vacío aumente (Alemania y Francia) o se estabilice (España).

Además del derroche de gasolina, el desgaste del vehículo y las horas de conducción improductiva que suponen los “kilómetros muertos o vacíos” también se traducen en emisiones contaminantes.

Esto choca de frente con la demanda de un transporte más sostenible y con los propios esfuerzos de la industria por reducir su huella de carbono. Los datos por países también son dispares en este caso, pero, más allá de las cifras, apuntan a un impacto más que significativo en la contaminación.

Minimizar o incluso eliminar los kilómetros en vacío no es tarea fácil. Requiere equilibrar las rutas, organizar los servicios de transporte de ida y vuelta de los clientes y garantizar que estos servicios se presten con vehículos adecuados, equipados, por ejemplo, con refrigeración si las mercancías son perecederas. El impulso de la digitalización y de las plataformas logísticas dotadas de inteligencia artificial puede ayudar a afrontar este reto.

En la Figura 14 se puede observar la evolución del TKM para cada uno de estos tres países. La tendencia prevista es la convergencia del transporte de toneladas por kilómetro para los tres países. Esto puede deberse a la presión ejercida por el aumento

de los precios del combustible, que está obligando a los transportistas a estandarizar las rutas rentables y a reducir el transporte en vacío.




Figura 14. Pronóstico del TKM utilizando modelos estadísticos SARIMA.

REFERENCIAS

1. Crainic, T.G.; Laporte, G. Planning models for freight transportation. *Eur. J. Oper. Res.* **1997**, *97*, 409–438. [[CrossRef](#)]
2. Baumol, W.J.; Vinod, H.D. An inventory theoretic model of freight transport demand. *Manag. Sci.* **1970**, *16*, 413–421. [[CrossRef](#)]
3. Oum, T.H. A cross sectional study of freight transport demand and rail-truck competition in Canada. *Bell J. Econ.* **1979**, *10*, 463–482. [[CrossRef](#)]
4. Costa, P. Using input-output to forecast freight transport demand. In *Freight Transport Planning and Logistics*; Springer: Berlin/Heidelberg, Germany, 1988; pp. 79–120.
5. Bennathan, E.; Fraser, J.; Thompson, L.S. *What Determines Demand for Freight Transport?* World Bank Publications: Chicago, IL, USA, 1992; Volume 998.
6. Szimba, E.; Ihrig, J.; Kraft, M.; Mitusch, K.; Chen, M.; Chahim, M.; van Meijeren, J.; Kiel, J.; Mandel, B.; Ulled, A.; et al. HIGH-TOOL—A strategic assessment tool for evaluating EU transport policies. *J. Shipp. Trade* **2018**, *3*, 11. [[CrossRef](#)]

7. Filová, A.; Hrdá, V. Managerial Evaluation of the Logistics Performance and Its Dependencies on Economies in Selected Countries. *Ekon.-Manazerske Spektrum* **2021**, *15*, 15–27. [[CrossRef](#)]
8. Jayathilaka, R.; Jayawardhana, C.; Embogama, N.; Jayasooriya, S.; Karunaratna, N.; Gamage, T.; Kuruppu, K. Gross domestic product and logistics performance index drive the world trade: A study based on all continents. *PLoS ONE* **2022**, *17*, e0264474. [[CrossRef](#)]
9. Meersman, H.; Van de Voorde, E. The relationship between economic activity and freight transport. In *Freight Transport Modelling*; Emerald Group Publishing Limited: Leeds, UK, 2013.
10. Chi, J.; Baek, J. Dynamic relationship between air transport demand and economic growth in the United States: A new look. *Transp. Policy* **2013**, *29*, 257–260. [[CrossRef](#)] [[PubMed](#)]
11. Ballingall, J.; Steel, D.; Briggs, P. *Decoupling Economic Activity and Transport Growth: The State of Play in New Zealand*; New Zealand Institute of Economic Research: Wellington, New Zealand, 2003.
12. McKinnon, A.C.; Woodburn, A. Logistical restructuring and road freight traffic growth. *Transportation* **1996**, *23*, 141–161. [[CrossRef](#)]
13. Tapio, P. Towards a theory of decoupling: Degrees of decoupling in the EU and the case of road traffic in Finland between 1970 and 2001. *Transp. Policy* **2005**, *12*, 137–151. [[CrossRef](#)]
14. Stead, D. Transport intensity in Europe—Indicators and trends. *Transp. Policy* **2001**, *8*, 29–46. [[CrossRef](#)]
15. Banister, D.; Stead, D. Reducing transport intensity. *Eur. J. Transp. Infrastruct. Res.* **2002**, *2*, 161–178. [[CrossRef](#)]
16. Tight, M.R.; Delle Site, P.; Meyer-Ruhle, O. Decoupling transport from economic growth: Towards transport sustainability in Europe. *Eur. J. Transp. Infrastruct. Res.* **2004**, *4*, 381–404.
17. Gray, D.; Anable, J.; Illingworth, L.; Graham, W. *Decoupling the Link between Economic Growth, Transport Growth and Carbon Emissions in Scotland*; Scottish Government: Edinburgh, UK, 2006.
18. McKinnon, A.C. Decoupling of road freight transport and economic growth trends in the UK: An exploratory analysis. *Transp. Rev.* **2007**, *27*, 37–64. [[CrossRef](#)]

19. Tapio, P.; Banister, D.; Luukkanen, J.; Vehmas, J.; Willamo, R. Energy and transport in comparison: Immaterialisation, dematerialisation and decarbonisation in the EU15 between 1970 and 2000. *Energy Policy* **2007**, *35*, 433–451. [[CrossRef](#)]
20. Andreoni, V.; Galmarini, S. Decoupling economic growth from carbon dioxide emissions: A decomposition analysis of Italian energy consumption. *Energy* **2012**, *44*, 682–691. [[CrossRef](#)]
21. Savy, M.; Burnham, J. *Freight Transport and the Modern Economy*; Routledge: Abingdon, UK, 2013.
22. Liimatainen, H.; Pollanen, M. The impact of sectoral economic development on the energy efficiency and CO2 emissions of road freight transport. *Transp. Policy* **2013**, *27*, 150–157. [[CrossRef](#)]
23. Stahel, W.R. Policy for material efficiency—Sustainable taxation as a departure from the throwaway society. *Philos. Trans. R. Soc. A Math. Phys. Eng. Sci.* **2013**, *371*, 20110567. [[CrossRef](#)] [[PubMed](#)] *Sustainability* **2024**, *16*, 0 17 of 17
24. Botzoris, G.N.; Galanis, A.T.; Profillidis, V.A.; Eliou, N.E. Coupling and decoupling relationships between energy consumption and air pollution from the transport sector and the economic activity. *Int. J. Energy Econ. Policy* **2015**, *5*, 949–954.
25. Alises, A.; Vassallo, J.M. Comparison of road freight transport trends in Europe. Coupling and decoupling factors from an Input-Output structural decomposition analysis. *Transp. Res. Part A Policy Pract.* **2015**, *82*, 141–157. [[CrossRef](#)]
26. Loo, B.P.; Banister, D. Decoupling transport from economic growth: Extending the debate to include environmental and social externalities. *J. Transp. Geogr.* **2016**, *57*, 134–144. [[CrossRef](#)]
27. Kos-Łabędowicz, J.; Urbanek, A. Do Information and Communications Technologies influence transport demand? An exploratory study in the European Union. *Transp. Res. Procedia* **2017**, *25*, 2660–2676. [[CrossRef](#)]
28. Profillidis, V.; Botzoris, G.; Galanis, A. Decoupling of economic activity from transport-related energy consumption: An análisis for European Union member countries. *Int. J. Innov. Sustain. Dev.* **2018**, *12*, 271–286. [[CrossRef](#)]
29. Eurostat. 2024. Available online: <https://ec.europa.eu/eurostat/> (accessed on 11 May 2024).
30. Smokers, R.; Tavasszy, L.; Chen, M.; Guis, E. Options for competitive and sustainable logistics. In *Sustainable Logistics (Transport and Sustainability)*; Emerald Group Publishing Limited: Leeds, UK, 2014; Volume 6.

31. Abid, M.; Sebri, M. Energy consumption-economic growth nexus: Does the level of aggregation matter? *Int. J. Energy Econ. Policy* **2012**, *2*, 55–62.
32. Tvaronavičienė, M. Towards Sustainable and Secure Development: Energy Efficiency Peculiarities in Transport Sector. *J. Secur. Sustain. Issues* **2018**, *7*, 719–725. [[CrossRef](#)] [[PubMed](#)]
33. Aza, C.; Escribano, A. Transporte, Infraestructuras y Crecimiento Económico en España; Working Paper Economics; Universidad Carlos III de Madrid: Getafe, Spain, 2019.
34. Benali, N.; Feki, R. Evaluation of the Relationship between Freight Transport, Energy Consumption, Economic Growth and Greenhouse Gas Emissions: The VECM Approach. *Environ Dev Sustain* **2020**, *22*, 1039–1049. [[CrossRef](#)]
35. Shafique, M.; Azam, A.; Rafiq, M.; Luo, X. Evaluating the Relationship between Freight Transport, Economic Prosperity, Urbanization, and CO₂ Emissions: Evidence from Hong Kong, Singapore, and South Korea. *Sustainability* **2020**, *12*, 10664. [[CrossRef](#)]
36. Sun, H.; Li, M.; Xue, Y. Examining the factors influencing transport sector CO₂ emissions and their efficiency in central China. *Sustainability* **2019**, *11*, 4712. [[CrossRef](#)]
37. Touratier-Muller, N.; Jausaud, J. Development of road freight transport indicators focused on sustainability to assist shippers: An analysis conducted in France through the FRET 21 programme. *Sustainability* **2018**, *13*, 9641. [[CrossRef](#)]
38. Pollanen, M.; Liljamo, T.; Kallionpää, E.; Liimatainen, H. Is there progress towards environmental sustainability among road haulage companies? *Sustainability* **2021**, *13*, 5845. [[CrossRef](#)]
39. Achour, H.; Belloumi, M. Investigating the causal relationship between transport infrastructure, transport energy consumption and economic growth in Tunisia. *Renew. Sustain. Energy Rev.* **2016**, *56*, 988–998. [[CrossRef](#)]
40. Saidi, S.; Shahbaz, M.; Akhtar, P. The long-run relationships between transport energy consumption, transport infrastructure, and economic growth in MENA countries. *Transp. Res. Part A Policy Pract.* **2018**, *111*, 78–95. [[CrossRef](#)]
41. Mohsin, M.; Abbas, Q.; Zhang, J.; Ikram, M.; Iqbal, N. Integrated effect of energy consumption, economic development, and population growth on CO₂ based environmental degradation: A case of transport sector. *Environ. Sci. Pollut. Res.* **2019**, *26*, 32824–32835. [[CrossRef](#)] [[PubMed](#)]
42. Wehner, J. Energy efficiency in logistics: An interactive approach to capacity utilisation. *Sustainability* **2018**, *10*, 1727. [[CrossRef](#)]

43. Osorio-Tejada, J.L.; Llera-Sastresa, E.; Hashim, A.H. Well-to-Wheels Approach for the Environmental Impact Assessment of Road Freight Services. *Sustainability* **2018**, *10*, 4467. [[CrossRef](#)]
44. Agency European Environment. Transport and Environment Report 2021. Available online: <https://www.eea.europa.eu/publications/transport-and-environment-report-2021> (accessed on 12 July 2024).
45. Andrés, L.; Padilla, E. Energy intensity in road freight transport of heavy goods vehicles in Spain. *Energy Policy* **2015**, *85*, 309–321. [[CrossRef](#)]
46. Box, G.E.; Jenkins, G.M.; Reinsel, G.C.; Ljung, G.M. *Time Series Analysis: Forecasting and Control*; John Wiley & Sons: Hoboken, NJ, USA, 2015.
47. Mushtaq, R. Augmented Dickey Fuller Test. SSRN. 2011. Available online: <https://ssrn.com/abstract=1911068> (accessed on 10 January 2024).

PARTE III: CONCLUSIONES Y LÍNEAS DE TRABAJO FUTURO

CONCLUSIONES

Para finalizar, se indican las conclusiones más significativas que se han encontrado durante el desarrollo de esta investigación. Estas conclusiones se encuentran también en los documentos publicados, pero se ha considerado conveniente plasmarlas un apartado diferente de este documento, para intentar seguir un formato más común para una tesis doctoral.

Por tanto, a continuación, en los siguientes apartados se exponen las conclusiones correspondientes a cada uno de los dos trabajos de investigación realizados, así como las conclusiones finales y las líneas de investigación por las en el futuro se considera conveniente continuar.

1.- CONCLUSIONES SOBRE EL TRABAJO ANÁLISIS DE SERIES TEMPORALES PARA LA PREDICCIÓN DEL PRECIO DEL ACERO LAMINADO EN CALIENTE EN ESPAÑA, MEDIANTE MODELOS NEURONALES NO LINEALES

Este estudio evalúa el desempeño de diferentes modelos neuronales no lineales (NIO, NAR, NARX) y sus parámetros en cuatro conjuntos de datos diferentes para predecir el precio del acero laminado en caliente. Los conjuntos de datos incluyen precios de la bolsa, indicadores económicos, precios de las materias primas utilizadas para producir acero y otras materias primas. Los modelos y conjuntos de datos utilizados en este estudio no se han aplicado con anterioridad a la previsión de precios del acero.

El estudio concluye que el modelo NARX tiene el mejor desempeño en la predicción del precio del acero laminado en caliente para la serie de datos 4, que es el precio de las materias primas utilizadas para producir acero. La serie de datos 1, que son los precios de la bolsa de tres importantes empresas productoras de acero a nivel mundial, también muestra un buen desempeño. Estas dos series de datos tienen una fuerte relación con el precio del acero, lo que indica la importancia de los precios de las materias primas y el desempeño de la bolsa para predecir los precios del acero. Sin embargo, la combinación de todos los conjuntos de datos no condujo a una mejora significativa.

Desde la perspectiva del ajuste de parámetros, se puede concluir que para algunos de los parámetros no existe un consenso que afecte a todos los modelos. Si bien los mejores valores para el número de retardos de entrada varían fuertemente de un modelo a otro, está claro cuáles son las mejores opciones para las neuronas ocultas (1) y el algoritmo de entrenamiento (“Gradiente Conjugado Escalado” y “Broyden-Fletcher-Goldfarb-Shanno Back-propagation”).

Las series de datos asociadas con los mejores resultados son “4.- Precio de las materias primas para la producción de acero” y “1.- Precios bursátiles de tres grandes empresas productoras de acero a nivel mundial”. Mientras que los peores resultados siempre se han obtenido utilizando la serie de datos “2.- Situación económica en España”.

Por lo tanto, el estudio encuentra que el precio de las materias primas utilizadas para producir acero y el desempeño bursátil de las empresas productoras de acero están correlacionados con la evolución de los precios del acero.

En futuras investigaciones, se ampliarán las series temporales y se utilizarán nuevas técnicas de soft-computing para mejorar los modelos de predicción existentes.

Para concluir, los mejores resultados (promedio de 10 ejecuciones) hasta el momento se han obtenido al aplicar el modelo NARX. El mejor se ha obtenido al aplicarlo al grupo de conjuntos de datos 4. Además, cabe mencionar que NARX supera claramente a NIO cuando se aplica tanto a las series individuales (1, 2, 3 y 4) como a las combinaciones de ellas (1+2, 1+2+3, 1+2+3+4).

2.- CONCLUSIONES SOBRE EL TRABAJO DIVERGENCIAS ENTRE LOS ESTADOS MIEMBROS DE LA UNIÓN EUROPEA SOBRE LA SOSTENIBILIDAD DEL TRASPORTE DE MERCANCÍAS POR CARRETERA

Los resultados de esta investigación, en la mayoría de los casos, revelaron un desacoplamiento entre las variables macroeconómicas. En la Tabla 1 se presenta un resumen de las cifras relevantes relacionadas con el transporte de mercancías por carretera, destacando su impacto positivo o negativo en el consumo de energía en el transporte por carretera como verde (mejor valor) o rojo (peor valor).

	Energy (%)		Road Freight Transport (%)						
	General Energy Use vs. GDP	Energy Consumption in Road Transport vs. GDP	TKM vs. GDP	TKM	Tonnes	VKM	Empty VKM	Journeys	Empty Journeys
EU-27	-39.21	-30.44	-17.63	19.31	1.31	15.16	7.67	-5.21	-2.24
Germany	-43.52	-36.84	-35.79	-2.92	13.80	0.15	12.21	11.84	11.30
Spain	-30.74	-24.12	1.16	26.97	1.91	22.76	10.55	-0.83	2.40
France	-34.85	-23.94	-28.06	-4.85	-18.60	-10.63	-36.59	-36.47	-27.31

Tabla 5. Resumen de los indicadores relevantes estudiados. Periodo de 2010 a 2022.

El análisis de estos datos lleva a las siguientes conclusiones:

- Existen casos evidentes de mejora energética, como Francia, que ha conseguido reducciones significativas del consumo energético en el transporte por carretera apoyadas en buenos indicadores de progreso en su transporte de mercancías por carretera (reducción de TKM o actividad de transporte y reducción de otros ratios relacionados con ineficiencias, como viajes en vacío y kilómetros en vacío). Este quizás no sea el único factor, pero es relevante para el alcance de esta investigación. En el futuro, se propondrá un estudio para analizar las actividades de cabotaje realizadas por otros países en Francia, con el fin de establecer la explicación para que la mejora de la energía no haya sido mayor.
- Alemania es un caso paradigmático. A pesar de haber experimentado un crecimiento de la actividad de transporte de mercancías por carretera y contrarrestar factores relacionados con ineficiencias, ha obtenido sin embargo mejoras significativas en su consumo energético. Este caso está sin duda apoyado por otros factores externos a nuestro estudio, que pueden ser abordados en futuras investigaciones sobre la desmaterialización en la economía alemana junto con posibles mejoras y reducciones en los procesos de transporte, podrían arrojar resultados relevantes al respecto.
- La Unión Europea en su conjunto ha experimentado una reducción del consumo energético del transporte en el contexto de un aumento de la actividad de transporte (TKM), reduciéndose el número de viajes, tanto cargados como vacíos, pero aumentando las distancias recorridas en vacío.
- A diferencia del resto de países de la UE estudiados, donde se produjo un desacoplamiento entre PIB vs. TKM, permitiendo evidenciar una mejora en la sostenibilidad del transporte, para España, estas dos variables están acopladas, por lo que no se produce dicha mejora. En los últimos años, en España, la actividad de transporte de mercancías por carretera (TKM) ha crecido proporcionalmente más que la actividad económica (PIB), y lo ha hecho de forma especialmente intensa respecto a las distancias recorridas en dichos viajes (Figura 2). Una vez más, futuras investigaciones sobre las actividades de cabotaje realizadas por vehículos españoles podrían revelar resultados sobresalientes, así como un mayor análisis de la eficiencia en la actividad de transporte.




Figura 2. Acoplamiento PIB-TKM para España.

En consecuencia, dados los datos muy detallados sobre el comportamiento de esta actividad de transporte de mercancías por carretera en España, sería deseable realizar un estudio específico de su comportamiento a lo largo de los años investigados. Como resultado, probablemente sería posible llegar a conclusiones más concretas encaminadas a la deseada reducción del consumo energético de esta actividad, considerando su impacto esencial en el consumo energético general.

Aunque hemos comentado las predicciones obtenidas con el modelo SARIMA aplicado a los datos de transporte en la UE, para futuras investigaciones, creemos que se debería estudiar, en profundidad, los resultados obtenidos al relacionarlos con otras variables energéticas y económicas.

3.- CONCLUSIONES FINALES Y FUTURAS LÍNEAS DE INVESTIGACIÓN

Estos dos trabajos de investigación presentados para esta tesis doctoral, intentan aportar nuevos conocimientos, utilizando técnicas de inteligencia artificial para la toma de decisiones en la gestión de las organizaciones.

En este sentido se han utilizado series de datos, empleando para la experimentación distintos modelos, hasta encontrar aquel que mejor se adapta a las problemáticas de gestión plantadas en cada caso.

Para lograr una ajustada predicción del precio de acero, se han utilizado como datos de entrada del modelo, los precios de las materias primas necesarias para obtener el acero y los precios obtenidos en las bolsas de valores de tres grandes empresas productoras de este metal, que operan en el mercado global. Se ha concluido que el modelo NARX es el que mejor se ha comportado en la predicción del precio del acero laminado en España y, por ello se recomienda su utilización a las empresas. Este importante resultado permitirá a los directivos tomar mejores decisiones de compra de esta materia prima y mejorar notablemente la eficiencia en la gestión de sus recursos.

Por otra parte, en esta tesis, se realiza una importante contribución para resolver problemas de ineficiencia en la gestión en el transporte de mercancías por carretera en la Unión Europea. En primer lugar, se logra definir el impacto positivo y negativo en el consumo de energía; aspecto fundamental para mejorar la sostenibilidad medio-ambiental, destacando positivamente Francia y negativamente España.

También se ha analizado el acoplamiento de variables macroeconómicas y distintas variables características de esta actividad del transporte en la Unión Europea, destacando que Francia y Alemania, así como la Unión Europea en su conjunto han reducido el consumo energético, reduciendo a su vez los viajes, pero aumentando las distancias recorridas, por lo que se considera que ha mejorado la eficiencia de este transporte por este desacoplamiento.

Al contrario, en España se ha encontrado un acoplamiento, por lo que no se observan mejoras, ya que las toneladas kilómetro transportadas han crecido con la misma intensidad que el producto interior bruto. Este resultado nos indica que se debe seguir profundizando su análisis para encontrar las causas de estas diferencias con la Unión Europea, e implementar mejoras que nos vayan acercando al resto de países y, así poder ser más competitivos.

Por último, respecto a las futuras líneas de investigación, se considera que se debe continuar con el análisis de los datos que se generen en los próximos años, para así poder establecer previsiones y conclusiones más ajustadas. Pero una línea importante en el ámbito de la sostenibilidad, sería analizar el transporte en vacío, dado que del análisis de los datos se ha encontrado que entre el 10% y el 30% de los viajes que realizan los camiones no llevan carga. Cualquier avance que se consiga, permitirá mejorar la eficiencia y la sostenibilidad ambiental en este sector.

BIBLIOGRAFÍA

Aboytes-Ojeda, M., Castillo-Villar, K. K., & Eksioglu, S. D. (2019). Modeling and optimization of biomass quality variability for decision support systems in biomass supply chains. *Annals of Operations Research*. <https://doi.org/10.1007/s10479-019-03477-8>.

Ahi, Alan A., et al. Advanced technologies and international business: A multidisciplinary analysis of the literature. *International Business Review*, 2022, vol. 31, no 4, p. 101967.

Alhijawi, B., & Awajan, A. (2023). Genetic algorithms: Theory, genetic operators, solutions, and applications. *Evolutionary Intelligence*. <https://doi.org/10.1007/s12065-023-00822-6>

Allal-Chérif, O., Simon-Moya, V., & Ballester, A. C. C. (2021). Intelligent purchasing: How artificial intelligence can redefine the purchasing function. *Journal of Business Research*, 124, 69–76. <https://doi.org/10.1016/j.jbusres.2020.11.050>

Álvarez, Y. (2022). La inteligencia artificial en la gestión de proyectos de inversión pública del Ministerio de Vivienda, Construcción y Saneamiento. *Ingeniería Industrial*, 97-121. Obtenido de <https://doi.org/10.26439/ing.ind2022.n.5802>

Alvarez-Mitchell, M. (2023). Creatives on strike: Talent versus technology. Forbes. Retrieved from <https://www.forbes.com/sites/forbesagencycouncil/2023/10/26/creatives-on-strike-talent-versus-technology/?sh=4352a92e69cb>

Ancarani, A., Di Mauro, C., & Mascali, F. (2019). Backshoring strategy and the adoption of Industry 4.0: Evidence from Europe. *Journal of World Business*, 54(4), 360–371.

Askarzadeh, A., & Rezazadeh, A. (2013). Artificial bee swarm optimization algorithm for parameters identification of solar cell models. *Applied Energy*, 102, 943–949.

Bag, S., Gupta, S., Kumar, A., & Sivarajah, U. (2021). An integrated artificial intelligence framework for knowledge creation and B2B marketing rational decision making for improving firm performance. *Industrial Marketing Management*, 92(92), 178–189. <https://doi.org/10.1016/j.indmarman.2020.12.001>

Balbaa, M. E., & Abdurashidova, M. S. (2024). The impact of artificial intelligence in decision making: A comprehensive review. *EPRA International Journal of Economics, Business and Management Studies (EBMS)*, 11(2), 27-38. <https://doi.org/10.36713/epra15747>

Baryannis, G., Validi, S., Dani, S., & Antoniou, G. (2019). Supply chain risk management and artificial intelligence: state of the art and future research directions. *International Journal of Production Research*, 57(7), 2179–2202.

- Beltrami, M., Orzes, G., Sarkis, J., & Sartor, M. (2021). Industry 4.0 and sustainability: Towards conceptualization and theory. *Journal of Cleaner Production*, 312, 127733. <https://doi.org/10.1016/j.jclepro.2021.127733>
- Benito, G. R. G., Cuervo-Cazurra, A., Mudambi, R., Pedersen, T., & Tallman, S. (2022). The future of global strategy. *Global Strategy Journal*, 12(3), 421–450. <https://doi.org/10.1002/gsj.1464>
- Bera, K., Schalper, K. A., Rimm, D. L., Velcheti, V., & Madabhushi, A. (2019). Artificial intelligence in digital pathology—New tools for diagnosis and precision oncology. *Nature Reviews Clinical Oncology*, 16(11), 703–715.
- Beşikçi, E. B., Arslan, O., Turan, O., & Ölçer, A. I. (2016). An artificial neural network based decision support system for energy efficient ship operations. *Computers & Operations Research*, 66, 393–401.
- Bhimani, A., & Willcocks, L. (2014). Digitization, ‘Big Data’ and the transformation of accounting information. *Accounting and Business Research*, 44(4), 469–490.
- Bidgoli, H. (2021). MIS: Management information systems. Cengage.
- Black, J. S., & van Esch, P. (2020). AI-enabled recruiting: What is it and how should a manager use it? *Business Horizons*, 63(2), 215–226. <https://doi.org/10.1016/j.bushor.2019.12.001>
- Blos, M. F., da Silva, R. M., & Wee, H.-M. (2018). A framework for designing supply chain disruptions management considering productive systems and carrier viewpoints. *International Journal of Production Research*, 56(15), 5045–5061. <https://doi.org/10.1080/00207543.2018.1442943>
- Botta, A., De Donato, W., Persico, V., & Pescapé, A. (2016). Integration of cloud computing and internet of things: A survey. *Future Generation Computer Systems*, 56, 684–700.
- Brynjolfsson, E., & McAfee, A. (2014). *The Second Machine Age: Work, Progress, and Prosperity in a Time of Brilliant*. W. W. Norton & Company.
- Budhwar, P., Malik, A., De Silva, M. T. T., & Thevisuthan, P. (2022). Artificial intelligence—Challenges and opportunities for international HRM: A review and research agenda. *The International Journal of Human Resource Management*, 33(6), 1065–1097. <https://doi.org/10.1080/09585192.2022.2035161>
- Bughin, J., Seong, J., Manyika, J., Chui, M., & Joshi, R. (2018). Notes From the Ai Frontier: Modeling the Impact of AI on the World Economy. McKinsey. Retrieved 01/12/2023 from <https://www.mckinsey.com/featured-insights/artificial->

[intelligence/notes-from-the-ai-frontier-mo13deling-the-impact-of-ai-on-the-world-economy](#)

Castellacci, F., & Viñas-Bardolet, C. (2019). Internet use and job satisfaction. *Computers in Human Behavior*, 90(141–152), 141–152. <https://doi.org/10.1016/j.chb.2018.09.001>

Cebeci, U. (2009). Fuzzy AHP-based decision support system for selecting ERP systems in textile industry by using balanced scorecard. *Expert Systems with Applications*, 36(5), 8900–8909.

Ciulli, F., y Kolk, A. (2023). International business, digital technologies and sustainable development: Connecting the dots. *Journal of World Business*, 58(4), 101445 <https://doi.org/10.1016/j.jwb.2023.101445>

Chan, C.Y. (2017). Advancements, prospects, and impacts of automated driving systems. *International Journal of Transportation Science and Technology*, 6(3), 208–216.

Chen, Z. (2023). Collaboration among recruiters and artificial intelligence: Removing human prejudices in employment. *Cognition, Technology and Work*, 25(1), 135–149. <https://doi.org/10.1007/s10111-022-00716-0>

Cheng, T. E., y Janiak, A. (2000). A permutation flow-shop scheduling problem with convex models of operation processing times. *Annals of Operations Research*, 96(1–4), 39–60.

Chou, Y. C., y Benjamin, C. O. (1992). An AI-based decision support system for naval ship design. *Naval Engineers Journal*, 104(3), 156–165.

Chowdhury, S., Dey, P., Joel-Edgar, S., Bhattacharya, S., Rodriguez Espindola, O., Abadie, A., & Truong, L. (2023). Unlocking the value of artificial intelligence in human resource management through AI capability framework. *Human Resource Management Review*, 33(1), 100899. <https://doi.org/10.1016/j.hrmr.2022.100899>

Crainic, T. G. et al. (2009). Models for Evaluating and Planning City Logistics Systems. *Transportation Science* 43(4):432-454. <https://doi.org/10.1287/trsc.1090.0279>

Dachs, B., Kinkel, S., & Jäger, A. (2019). Bringing it all back home? Backshoring of manufacturing activities and the adoption of Industry 4.0 technologies. *Journal of World Business*, 54(6), 101017. <https://doi.org/10.1016/j.jwb.2019.101017>

De Sousa Jabbour, A. B. L., Jabbour, C. J. C., Godinho Filho, M., & Roubaud, D. (2018). Industry 4.0 and the circular economy: a proposed research agenda and original roadmap for sustainable operations. *Annals of Operations Research*, 270(1–2), 273–286.

- Duan, Y., Edwards, J. S., & Dwivedi, Y. K. (2019). Artificial intelligence for decision making in the era of Big Data—Evolution, challenges and research agenda. *International Journal of Information Management*, 48, 63–71.
- Efendigil, T., Önüt, S., & Kahraman, C. (2009). A decision support system for demand forecasting with artificial neural networks and neuro-fuzzy models: A comparative analysis. *Expert Systems with Applications*, 36(3), 6697–6707.
- Elhadi, A. (2023). Collaborative translation and meaning making: Using English language learners' first language as a resource for language learning and academic achievement in the classroom. ProQuest Dissertations Publishing
- Fleck, J. (2021). Development and establishment in artificial intelligence. In *Artificial intelligence* (pp. 2–10). Routledge Library Editions.
- Gayathri, R., & Uma, V. (2018). Ontology based knowledge representation technique, domain modeling languages and planners for robotic path planning: A survey. *ICT Express*, 4(2), 69–74.
- Georgieva, K. (2024). La economía mundial transformada por la inteligencia artificial ha de beneficiar a la humanidad. <https://www.imf.org/es/Blogs/Articles/2024/01/14/ai-will-transform-the-global-economy-lets-make-sure-it-benefits-humanity>
- Gujarati, D.N. y D.C. Porter (2010). *Econometría*. México: McGraw-Hill.
- Gupta, S., Modgil, S., Bhattacharyya, S., & Bose, I. (2022). Artificial intelligence for decision support systems in the field of operations research: review and future scope of research. *Annals of Operations Research*, 308(1), 215-274.
- Haan, K., & Watts, R. (2023). How businesses are using artificial intelligence in 2023. Retrieved from <https://www.forbes.com/advisor/business/software/ai-in-business/>
- Hamet, P., & Tremblay, J. (2017). Artificial intelligence in medicine. *Metabolism*, 69, S36–S40
- Hashem, I. A. T., Yaqoob, I., Anuar, N. B., Mokhtar, S., Gani, A., & Khan, S. U. (2015). The rise of “big data” on cloud computing: Review and open research issues. *Information Systems*, 47, 98–115.
- Hastie, T. et al. (2009). *The elements of statistical learning: Data Mining, Inference, and Prediction*. Springer.
- Hopfield, J.J. (1982). Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the National Academy of Sciences USA*, 79, 2554- 2558.

Hopfield, J.J. (1984). Neurons with graded response have collective computational properties like those of two state neurons. *Proceedings of the National Academy of Sciences USA*, 81. 3088-3092.

Hopfield, J.J., & Tank, D.W. (1985). Neural computation of decisions in optimization problems. *Biological Cybernetics*, 52. 1-25.
<https://doi.org/10.1080/19368623.2019.1647124>

Horodyski, P. (2023). Applicants' perception of artificial intelligence in the recruitment process. *Computers in Human Behavior Reports*, 11, 100303.
<https://doi.org/10.1016/j.chbr.2023.100303>

Hughes, C. (2023). Maximizing business potential with AI-generated plans: Tools and tips for success. *Forbes Business Council*. Retrieved from
<https://www.forbes.com/sites/forbesbusinesscouncil/2023/05/03/maximizing-business-potential-with-ai-generated-plans-tools-and-tips-for-success/?sh=75d025c06fd3>

Iansiti, M., & Lakhani, K. R. (2020). Competing in the age of AI. *Harvard Business Review*, 98(1), 60–67.

Jarrahi, M. H. (2018). Artificial intelligence and the future of work: Human-AI symbiosis in organizational decision making. *Business Horizons*, 61(4), 577–586.
<https://doi.org/10.1016/j.bushor.2018.03.007> .

Jones, E. (2023). Digital disruption: Artificial intelligence and international trade policy. *Oxford Review of Economic Policy*, 39(1), 70–84.
<https://doi.org/10.1093/oxrep/grac049>

Jumper, J. et al., (2021). Highly accurate protein structure prediction with AlphaFold *Nature*, vol. 596, pp. 583-589. DOI: <https://doi.org/10.1038/s41586-021-03828-1>

Kaplan, A., & Haenlein, M. (2018). Siri, Siri, in my hand: Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. *Business Horizons*. <https://doi.org/10.1016/j.bushor.2018.08.004>.

Karacapilidis, N. I., & Pappis, C. P. (1997). A framework for group decision support systems: Combining AI tools and OR techniques. *European Journal of Operational Research*, 103(2), 373–388.

Keith, A. J., & Ahner, D. K. (2019). A survey of decision making and optimization under uncertainty. *Annals of Operations Research*. <https://doi.org/10.1007/s10479-019-03431-8>.

Kirlar, B. B., Ergün, S., Gök, S. Z. A., & Weber, G. W. (2018). A game-theoretical and cryptographical approach to crypto-cloud computing and its economical and financial aspects. *Annals of Operations Research*, 260(1–2), 217–231.

Kobbacy, K. & Vadera, S. (2011). A survey of AI in operations management from 2005 to 2009. *Journal of Manufacturing Technology Management*, 22(6), 706–733. <https://doi.org/10.1108/17410381111149602>

Kouziokas, G. N., & Perakis, K. (2017). Decision support system based on artificial intelligence, GIS and remote sensing for sustainable public and judicial management. *European Journal of Sustainable Development*, 6(3), 397.

Laguna-Salvadó, L., Lauras, M., Okongwu, U., & Comes, T. (2019). A multicriteria master planning DSS for a sustainable humanitarian supply chain. *Annals of Operations Research*, 283(1), 1303–1343.

Leontaritis, I. J. and S. A. Billings (1985). Input-output parametric models for non-linear systems Part I: deterministic non-linear systems. *International Journal of Control* 41(2): 303-328.

Li, L., Wang, Y., & Zhang, Y. (2021). Analysis on the application of artificial intelligence in cross-border E-commerce. Paper presented at the 6th Annual International Conference on Social Science and Contemporary Humanity Development (SSCHD 2020).

Lin, T., W. Horne and C. Lee Giles (1998). How embedded memory in recurrent neural network architectures helps learning long-term temporal dependencies.

Lui, A., & Lamb, G. W. (2018). Artificial intelligence and augmented intelligence collaboration: Regaining trust and confidence in the financial sector. *Information & Communications Technology Law*, 27(3), 267–283.

Luo, Y., & Zahra, S. A. (2023). Industry 4.0 in international business research. *Journal of International Business Studies*, 54(3), 403–417. <https://doi.org/10.1057/s41267-022-00577-9>

Malik, A., Budhwar, P., & Kazmi, B. A. (2023). Artificial intelligence (AI)- assisted HRM: Towards an extended strategic framework. *Human Resource Management Rev*

Manning, C. (2020). Artificial intelligence definitions. HAI StanfordUniversity.

Mar-Ortiz, J., Castillo-García, N., & Gracia, M. D. (2019). A decision support system for a capacity management problem at a container terminal. *International Journal of Production Economics*. <https://doi.org/10.1016/j.ijpe.2019.09.023>.

- Massari, G. F., & Giannoccaro, I. (2021). Investigating the effect of horizontal coopeitition on supply chain resilience in complex and turbulent environments. *International Journal of Production Economics*, 237, 108150. <https://doi.org/10.1016/j.ijpe.2021.108150>
- McCarthy, J., Minsky, M. L., Rochester, N., & Shannon, C. E. (1955). A pro-posal for the Dartmouth summer research project on artificial intelli-gence, August 31, 1955 *AI Magazine*,27(4), 12 DOI: <https://doi.org/10.1609/aimag.v27i4.1904>
- Meltzer, J. P. (2018). The impact of artificial intelligence on international trade. Retrieved from <https://www.brookings.edu/articles/theimpact-of-artificial-intelligence-on-international-trade/>
- Menezes, J. M. P. and G. A. Barreto (2008). Long-term time series prediction with the NARX network: An empirical evaluation. *Neurocomputing* 71(16): 3335-3343.
- Menzies, J. et al. (2024). Artificial intelligence for international business: Its use, challenges, and suggestions for future research and practice. *International Business Review*, 66(2), 185-200. <https://doi.org/10.1002/tie.22370>
- Messner, W. (2022). Advancing our understanding of cultural heterogeneity with unsupervised machine learning. *Journal of International Management*, 28(2), 100885. <https://doi.org/10.1016/j.intman.2021.100885>
- Michael P. (1987). *An Introduction to Econometrics*. New York: Basil Blackwell.
- Min, H. (2010). Artificial intelligence in supply chain management: Theory and applications. *International Journal of Logistics Research and Applications*, 13(1), 13–39.
- Monteserin, A., & Amandi, A. (2011). Argumentation-based negotiation planning for autonomous agents. *Decision Support Systems*, 51(3), 532–548.
- Moslemi, H. & Zandieh, M. (2011). Comparisons of some improving strategies on MOPSO for multi-objective (r, Q) inventory system. *Expert Systems with Applications*, 38(10): 12051-12057. <https://doi.org/10.1016/j.eswa.2011.01.169>
- Nedèlková, Z., Lindroth, P., Patriksson, M.&Strömberg, A. B. (2018). Efficient solution of many instances of a simulation-based optimization problem utilizing a partition of the decision space. *Annals of Operations Research*, 265(1), 93–118.
- Neubert, M. (2018). The impact of digitalization on the speed of internationalization of lean global startups. *Technology Innovation Management Review*, 8(5), 44–54. <https://doi.org/10.22215/timreview/1158>

Nuttal, K. (2022). 10 use cases for AI across industries. Retrieved from <https://www.deloitte.com/au/en/services/consulting/perspectives/10-use-cases-for-ai-across-industries.html>

OCDE (2022). Artificial intelligence and international trade. Retrieved from <https://www.oecd-ilibrary.org/docserver/13212d3een.pdf?expires=1713456497&id=id&accname=guest&checksum=1E4A6F8218BF8C4A6B54126F73FAFCE9>

Ore, O., & Sposato, M. (2021). Opportunities and risks of artificial intelligence in recruitment and selection. *International Journal of Organizational Analysis*, 30(6), 1771–1782. <https://doi.org/10.1108/ijoa07-2020-2291>

Paul, J. et al. (2021). Scientific procedures and rationales for systematic literature reviews (SPAR-4-SLR) . *Int J Consum Stud* 45(4). <https://doi.org/10.1111/ijcs.12695>

Perraju, T. (2013). Artificial intelligence and decision support systems. *International Journal of Advanced Research in IT and Engineering*, 2(4), 17–26.

Prentice, C., Dominique Lopes, S., & Wang, X. (2020). Emotional intelligence or artificial intelligence—An employee perspective. *Journal of Hospitality Marketing & Management*, 29(4), 377–403. <https://doi.org/10.1080/19368623.2019.1647124>

Rumelhart, D.E., & Zipser, D. (1985). Feature discovery by competitive learning. *Cognitive Science*, 9, 75-112.

Russell, S., & Norvig, P. (2016). *Artificial Intelligence: A Modern Approach*. Pearson.

Sahebjamnia, N., Torabi, S. A., & Mansouri, S. A. (2017). A hybrid decision support system for managing humanitarian relief chains. *Decision Support Systems*, 95, 12–26.

Sang, B. (2021). Application of genetic algorithm and BP neural network in supply chain finance under information sharing. *Journal of Computational and Applied Mathematics*, 384, 113170. <https://doi.org/10.1016/j.cam.2020.113170>

Saranya, K., Jegaraj, J. J. R., Kumar, K. R., & Rao, G. V. (2018). Artificial intelligence based selection of optimal cutting tool and process parameters for effective turning and milling operations. *Journal of the Institution of Engineers (India): Series C*, 99(4), 381–392.

Scott, J., Ho, W., Dey, P. K., & Talluri, S. (2015). A decision support system for supplier selection and order allocation in stochastic, multi-stakeholder and multi-criteria environments. *International Journal of Production Economics*, 166, 226–237.

- Shi, J. (2022). Research on optimization of cross-border e-commerce logistics distribution network in the context of artificial intelligence. *Mobile Information Systems*, 2022, 3022280. <https://doi.org/10.1155/2022/3022280>
- Singh, A. K., Subramanian, N., Pawar, K. S., & Bai, R. (2018). Cold chain configuration design: Location allocation decision-making using coordination, value deterioration, and big data approximation. *Annals of Operations Research*, 270(1–2), 433–457.
- Soori, M., Arezoo, B., & Dastres, R. (2023a). Artificial intelligence, machine learning and deep learning in advanced robotics: A review. *Cognitive Robotics*, 3, 54–70 <https://doi.org/10.1016/j.cogr.2023.04.001>
- Soori, M., Arezoo, B., & Dastres, R. (2023b). Artificial neural networks in supply chain management, a review. *Journal of Economy and Technology*, 1, 179–196. <https://doi.org/10.1016/j.ject.2023.11.002>
- Srinivasani, A. (2018). *Cloud computing basics*. Springer.
- Stair, R. M., Reynolds, G. W., Bryant, J., Frydenberg, M., Greenberg, H., & Schell, G. P. (2021). *Principles of information systems* (14th ed.). Cengage.
- Stallkamp, M., & Schotter, A. P. J. (2021). Platforms without borders? The international strategies of digital platform firms. *Global Strategy Journal*, 11(1), 58–80. <https://doi.org/10.1002/gsj.1336>
- Suzuki, K., & Chen, Y. (Eds.). (2018). *Artificial intelligence in decision support systems for diagnosis in medical imaging*, (Vol. 140). New York: Springer.
- Svozil, D., Kvasnicka, V., & Pospichal, J. (1997). Introduction to multi-layer feed-forward neural networks. *Chemometrics and Intelligent Laboratory Systems*, 39(1), 43–62.
- Szkudlarek, B., Osland, J. S., Nardon, L., & Zander, L. (2020). Communication and culture in international business—Moving the field forward. *Journal of World Business*, 55(6), 101126. <https://doi.org/10.1016/j.jwb.2020.101126>
- Taleizadeh, A. A., Tavakoli, S., & San-José, L. A. (2018). A lot sizing model with advance payment and planned backordering. *Annals of Operations Research*, 271(2), 1001–1022.
- Tambe, P. et al. (2019). Artificial Intelligence in human resources management: Challenges and a path forward. *California Management Review*, 61(4). <https://doi.org/10.1177/0008125619867910>
- Tang, A., Tam, R., Cadrin-Chênevert, A., Guest, W., Chong, J., Barfett, J., et al. (2018). Canadian Association of Radiologists white paper on artificial intelligence in radiology. *Canadian Association of Radiologists Journal*, 69(2), 120–135.

Tarique, I., Briscoe, D. R., & Schuler, R. S. (2022). International human resource management. Policies and practices for multinational enterprises. Routledge.

Toorajipour, R. et al. (2021). Artificial intelligence in supply chain management: A systematic literature review. *Journal of Business Research* 122: 502-517. DOI:[10.1016/j.jbusres.2020.09.009](https://doi.org/10.1016/j.jbusres.2020.09.009)

Tsolakis, N., Schumacher, R., Dora, M., & Kumar, M. (2023). Artificial intelligence and blockchain implementation in supply chains: A pathway to sustainability and data monetisation? *Annals of Operations Research*, 327(1), 157–210. <https://doi.org/10.1007/s10479-022-04785-2>

Turing, A. (1950). Computing Machinery and Intelligence. *Mind* 49, 433-460.

Vrontis, D., Christofi, M., Pereira, V., Tarba, S., Makrides, A., & Trichina, E. (2021). Artificial intelligence, robotics, advanced technologies and human resource management: A systematic review. *The International Journal of Human Resource Management*, 33(6), 1237–1266. <https://doi.org/10.1080/09585192.2020.1871398>

Wamba, S. et al. (2017). Big data analytics and firm performance: Effect of dynamic capabilities. *Journal of Business Research* 70: 356-365. <https://doi.org/10.1016/j.jbusres.2016.08.009>

Wright, S. A., & Schultz, A. E. (2018). The rising tide of artificial intelligence and business automation: Developing an ethical framework. *Business Horizons*, 61(6), 823–832.

Xie, D., & He, Y. (2022). Marketing strategy of rural tourism based on bigdata and artificial intelligence. *Mobile Information Systems*, 2022, 1-7. <https://doi.org/10.1155/2022/915435>

Yang, R., Lee, C. Y., Liu, Q., & Zheng, S. (2019). A carrier–shipper contract under asymmetric information in the ocean transport industry. *Annals of Operations Research*, 273(1–2), 377–408.

Zhu, T., & Liu, G. (2022). A novel hybrid methodology to study the risk management of prefabricated building supply chains: An outlook for sustainability. *Sustainability*, 15(1), 361. <https://doi.org/10.3390/su15010361>

Zoom. (2023). Viewing captions in another language. Retrieved from https://support.zoom.com/hc/en/article?id=zm_kb&sysparm_article=KB0060844

Zukrowska, K. (2021). Artificial intelligence (AI) and international trade. In _ A. Visvizi & M. Bodziany (Eds.), *Advanced sciences and technologies for security applications* (pp. 225–240). World Health Organization.

WEBGRAFÍA

<https://www.imf.org/es/Blogs/Articles/2024/01/14/ai-will-transform-the-global-economy-lets-make-sure-it-benefits-humanity> (consulta junio/2024).

<https://deepmind.google/about/> (consulta abril/2024).

<https://deepmind.google/technologies/alphago/> (consulta abril/2024).

<https://www.ibm.com/es-es/topics/autoregressive-model> (consulta abril/2024).

<https://www.dictador.com/> (consulta enero/2024).

<https://computerhoy.com/tecnologia/mika-primer-ceo-robot-inteligencia-artificial-compania-dictador-1282992> (consulta enero/2024).

<https://www.tecnicasdetrading.com/2024/07/modelo-sarima.html> (consulta enero/2024).

<https://chatgpt.com/> (consulta diciembre/2023).

<https://www.bing.com/?FORM=Z9FD1> (consulta diciembre/2023).

<https://gemini.google.com/> (consulta diciembre/2023).

<https://bostondynamics.com/about/>(consulta diciembre/2023).

<https://www.imf.org/es/Blogs/Articles/2024/01/14/ai-will-transform-the-global-economy-lets-make-sure-it-benefits-humanity>) (consulta diciembre/2023).

<https://www.oecdilibrary.org/docserver/13212d3een.pdf?expires=1713456497&id=id&accname=guest&checksum=1E4A6F8218BF8C4A6B54126F73FAFCE9> (consulta diciembre/2023).

<https://www.brookings.edu/articles/theimpact-of-artificial-intelligence-on-international-trade/> (consulta diciembre/2023).

ACRÓNIMOS

ANN. Redes Neuronales Artificiales.

AR. Proceso autorregresivo.

ARIMA. Proceso autorregresivo integrado de media móvil.

ARMA. Proceso autorregresivo de media móvil.

ARX. Modelo autorregresivo (AR) de entrada exógena (X).

CEO. Chief executive officer. Máximo ejecutivo de la organización.

DL. Deep learning.

ERP. Enterprise resource planning. Planificación de recursos empresariales.

FMI. Fondo monetario internacional.

GEI. Gases de efecto invernadero.

I. Variables integradas.

IA. Inteligencia Artificial

IBM. International business machines.

MA. Media móvil.

ML. Aprendizaje Automático.

NAR. Non lineal autoregresive.

NARX. Non lineal autoregressive with exogenous input.

NIO. Non lineal input-output.

OCDE. Organización para cooperación y el desarrollo económico.

RNA. Modelos de redes neuronales

SAP. Programas para el sistema de análisis.

SARIMA. Modelo autorregresivo integrado de media móvil estacional.

ANEXO

PUBLICACIÓN INVESTIGACIÓN 1

La primera investigación titulada: ANÁLISIS DE SERIES TEMPORALES PARA LA PREDICCIÓN DEL PRECIO DEL ACERO LAMINADO EN CALIENTE EN ESPAÑA, MEDIANTE MODELOS NEURONALES NO LINEALES y cuya referencia es:

Alcalde, R., García, S., Manzanedo, M., Basurto, N., de Armiño, C. A., Urda, D., & Alonso, B. (2024). Analyzing time series to forecast hot rolled coil steel price in Spain by means of neural non-linear models. *Logic Journal of the IGPL*, jzae060.

Se puede encontrar en la dirección electrónica:

<https://doi.org/10.1093/jigpal/jzae060>

La segunda investigación titulada: DIVERGENCIAS ENTRE LOS ESTADOS MIEMBROS DE LA UNIÓN EUROPEA SOBRE LA SOSTENIBILIDAD DEL TRASPORTE DE MERCANCÍAS POR CARRETERA y cuya referencia es:

Manzanedo, M., Alonso de Armiño, C., Basurto, N., Alcalde, R., & Alonso, B. (2024). Divergences between EU Members on the Sustainability of Road Freight Transport. *Sustainability*, 16(15), 6268.

Se puede encontrar en la dirección electrónica

| <https://doi.org/10.3390/su16156268>