

UNIVERSIDAD POLITÉCNICA DE MADRID
Escuela Técnica Superior de Ingenieros Industriales



**Transportation: metodología para la
aplicación de la Inteligencia Artificial para
optimizar la movilidad ferroviaria existente**

TESIS DOCTORAL

Presentada para optar al título de Doctor por:

Pablo Garrido Martínez–Llop

Grado en Ingeniería en Tecnologías Industriales y Máster Habilitante en
Ingeniería Industrial

Madrid, 2024



UNIVERSIDAD POLITÉCNICA DE MADRID
Escuela Técnica Superior de Ingenieros Industriales

Doctorado en Ingeniería Mecánica

**Transportation: metodología para la
aplicación de la Inteligencia Artificial para
optimizar la movilidad ferroviaria existente**

TESIS DOCTORAL

Presentada para optar al título de Doctor por:

Pablo Garrido Martínez–Llop

Grado en Ingeniería en Tecnologías Industriales y Máster Habilitante en
Ingeniería Industrial

Bajo la dirección de:
Dr. Juan de Dios Sanz Bobi

Madrid, 2024

Título: Trainsportation: metodología para la aplicación de la Inteligencia Artificial para optimizar la movilidad ferroviaria existente

Autor: Pablo Garrido Martínez-Llop

Programa de Doctorado: Ingeniería Mecánica

Dirección de Tesis:

Dr. Juan de Dios Sanz Bobi, Profesor Contratado Doctor, Universidad Politécnica de Madrid. (Director)

Revisores Externos:

Tribunal de Tesis:

Fecha de Defensa de Tesis:

Cuando haces algo por lo demás, podrá salir mejor, o peor, pero nunca saldrá mal..
P.G.M-Ll.

Agradecimientos

En primer lugar, me gustaría agradecer a mi familia, a mis padres (Jerónimo y Marta) y hermanos (Jorge, Javier y Martita), por darme siempre todo su cariño y apoyo, y estar siempre que lo necesito. Gracias por entender mi ajetreada y ocupada vida, y ayudarme en todos mis desafíos profesionales y personales.

Gracias también a mis amigos, por su incondicional apoyo y comprensión con todo lo que hago a nivel profesional y personal (Mangueros, Road to Santiago, Jotapols).

Un especial agradecimiento a Miguel Castro, gran referente y mentor desde el primer día que pisé la Universidad, por su desinteresado apoyo, dedicación, y cuidadosa revisión de este documento. Gracias por tu inestimable ayuda y tu apoyo incondicional.

Agradezco profundamente a Juan de Dios, profesor mío de ferrocarriles, mentor durante mi etapa profesional, director de esta tesis doctoral, y amigo, por todo lo que me ha enseñado, apoyado y guiado en mi vida académica y profesional en el sector ferroviario. Gracias por toda tu ayuda para realizar esta tesis, si no he tirado la toalla ha sido gracias a ti.

Quiero agradecer a todos los profesores y compañeros de la UPM, especialmente a mi amiga Paloma García y mi amigo Luis Fernández, por su apoyo y motivación durante estos años como docente en la Escuela. También a M^a Ángeles, Manolo, Juan Antonio, Bernardo, Miguel, Juanjo y Patricia por su amistad y su ayuda para terminar la tesis doctoral. También agradezco a Víctor Muñoz, compañero y amigo, por su profesionalidad, apoyo y la revisión que con tanto cariño ha realizado de este documento.

Agradezco a Talgo y a mis compañeros su apoyo constante para continuar mi labor académica en la Universidad, acercando ambas instituciones a través del Aula Talgo. Especialmente agradezco a Belén su apoyo incondicional y su preocupación por el avance de mi tesis doctoral.

Y por último, y más importante, dedico esta tesis doctoral a mi abuelo Cristóbal, a mi abuela Isabel, a mi abuela Piloli y a mi tía Maruja.

Va por todos vosotros.

Abstract

We find ourselves in a daily changing reality that is full of challenges from different points of view, influenced also by unpredictable situations, such as a pandemic or wars, with important consequences in the society of the 21st century.

Technology is evolving faster than companies or society are able to assimilate. In the coming years, the vast majority of companies will undergo a digital transformation process that will make them more competent, optimizing their processes and increasing productivity and profits, as a result of the implementation of artificial intelligence.

Artificial intelligence is considered the spearhead of scientific and technological progress, among other reasons, due to the increase in available information and its processing. The IT sector is therefore booming, and many companies in this sector aim to develop and implement models and processes that achieve maximum economic optimization, increasing the competitiveness of companies.

New technologies and economic growth must be associated with the idea of maintaining, preserving and improving the environment, leading countries towards a model of sustainability that optimizes energy resources and reduces emissions. The Sustainable Development Goals, set within the framework of the 2030 Agenda, were born with this purpose. The relevance of these goals is increasing over the years, and it is included in most government policies of the different countries.

Society is also influenced by technological evolution and paradigm change. Family reconciliation and flexibility are enhanced by the emergence of teleworking, and professions that allow the assimilation of geographical distance. This has a direct impact on people's mobility.

Until the last century, transport was understood as the movement of a person or goods from an initial point, called origin, to an end point, called destination. Improvements to date have focused either on increasing the frequency and schedules offered, or on reducing the associated costs for the end user. The vehicles used have also evolved as a result of technological progress.

However, this transport service has not been analyzed from a global perspective, since energy efficiency, accident rate, energy consumption, sustainability, adaptation of supply and demand, auxiliary services to the traveler as part of the user experience, combination of transport services, ... All this leads to evolve the traditional concept of transport to the concept of mobility.

In the freight sector, the aim is to increase rail transport and reduce road transport due to its high environmental impact. As for passenger transport, air transport in regional or national areas is already being limited.

A clear objective is also to reduce the use of private cars, and to offload more of the roads in both urban and interurban areas. This is known as decarbonization of transport. To this end, railroad public transport must continue to be promoted, along with the growing need to prioritize it for reasons of energy, sustainability and both economic and energy efficiency.

At the European level, a clear commitment to the rail sector as the preferred means of transport is being studied in detail through the Joint Undertaking *Europe's Rail*, (*EU-Rail*).

The objective of *EU-Rail* is to promote an integrated high-capacity European rail network by eliminating interoperability bottlenecks, offering solutions for full integration (traffic management, vehicles, infrastructure and services) and achieving faster adoption and deployment of innovations through funded projects. *EU-Rail* is committed to using digitalization and automation to reduce costs in the rail industry, increase capacity and enhance flexibility and reliability.

The objectives of *EU-Rail* are aligned with EU policy regarding the vision of the railway industry and the challenges inherent in the transformation of the railway system. It is essential to respond to changing user demands, improve performance and capacity, reduce costs, contribute to more sustainable transport, provide a harmonized approach to adapting to changes in the industry, give rail a greater role in European transport and travel, and contribute to the increased competitiveness of the EU rail supply industry.

Despite working on the aforementioned improvements, there are still a number of mobility-related challenges to be addressed in the coming years. They can be classified into two categories: resolution of problems already known nowadays, and future challenges that will derive from the evolution of technology applied to the transportation sector.

As for the existing challenges, it is worth highlighting the importance of optimizing the offer and demand of transport using artificial intelligence as a priority tool, including the application throughout the global operation cycle, in order to optimize the economic and human resources allocated to transport services. This will lead to a real implementation of Industry 4.0 in the transport sector, and will undoubtedly help to gradually balance transport costs and times for all citizens within a reasonable range. It is necessary to ensure accessibility to a reliable and complete transport network to all citizens, given that there are depopulated or difficult to access regions that prevent adequate progress of these populations, both economically and socially.

Looking ahead, technological developments will continue to shape a new approach to mobility, with new approaches to be investigated. For example, the evolution of electric vehicles, or the emergence of hydrogen or other alternative drive technology, will have a direct impact on the infrastructure and organization of the transport sector.

Research is currently underway on the vehicle sharing model, generating a fleet management model similar to that already existing in the public sector (e.g., with buses).

With the emergence of several private electric vehicle rental companies, the possibility of charging the battery on the move, or even being able to charge a vehicle with another vehicle that is in circulation, will be analyzed over the next few years as a concept of energy sharing between the vehicle fleet itself.

The future of transportation is still very uncertain, although it is true that the optimization of economic and energy resources will always be a fundamental task in the sector.

Today, artificial intelligence is mainly helping in the improvement of the current mobility situation. It is useful to study the data on the movements of people and goods, to compare it with the real needs, and to be able to more easily adapt the supply and demand of transport services.

In addition, the use of artificial intelligence helps to optimize the operation and maintenance of both infrastructure and vehicles, achieving higher availability and reliability rates with the lowest possible number of resources invested.

This PhD thesis focuses on the creation of a methodology for the optimization of the existing mobility in the railway sector, being possible to extrapolate it to other means of transport and at any geographical scale, in order to obtain a more complete vision.

This methodology proposes in one of the phases the use of artificial intelligence, in order to optimize passenger rail mobility as a particular applied case.

In the railway sector, three main stakeholders are involved: the operator, the infrastructure manager, and the rolling stock manufacturer and maintainer.

They are usually different companies, so it becomes complicated to work on a problem from a general point of view, because each one tries to optimize its scope without taking into account the other stakeholders. This generates optimized solutions in isolation (relative extremes), but not an optimal global solution for the industry as a whole (absolute extremes).

In addition, with the growing volume of data being collected from trains or infrastructure, there is still a lack of information sharing between the different companies to generate added value to rail transport. Progressively, it is desirable to change this trend, in order to work on solutions that are potentially beneficial for the sector as a whole. Data should be shared for the good purpose of finding continuous improvement and global optimization that benefits all parties.

A state-of-the-art study has been carried out, based on 72 research papers related to the application of new technologies and artificial intelligence, in the three main interest groups of railway mobility.

As a general conclusion, it can be observed that only 9% of the papers deal with issues incorporating all the stakeholders, with more than 50% of the cases in which only one of the participants is involved in the treatment and resolution of the exposed problem.

This shows that the existing problems and challenges related to rail mobility are not being addressed in a cross-cutting manner, and therefore this biased and unshared perspective generates partial solutions that are far from reaching the optimum for all parties involved. There is a wide field of improvement in terms of analysis and problem solving, and this is one of the key points that the methodology of this PhD thesis tries to solve.

The main themes of the papers studied revolve around safety, reliability and maintainability, sustainability and user experience. More than half of the papers studied deal with the optimization and improvement of reliability and maintainability, in line with the background

information on the growing need for research in this field to significantly improve the efficiency of passenger and freight railway operations. The second most studied field is safety, with the intention of further optimizing and improving this area to reduce risks and liability for human error.

The most studied problems are those related to the detection of obstacles on the track and predictive maintenance, both of infrastructure and rolling stock. Another existing line of research is related to the redundancy and automation of safety supervision using new technologies. Sustainability and user experience are fields in which research is beginning to be strengthened, and still has a long way to go in terms of study and future application. Other topics such as cybersecurity and communications are and will continue to be of interest in the future, given the constant evolution of technology.

From a mathematical point of view, deep learning is one of the most widely applied artificial intelligence techniques in the various papers analyzed. In general, neural networks show very positive results, i.e. with a low error rate and sufficient efficiency for the resolution of various classification or regression problems. These algorithms have a linear and a non-linear calculation part, which improve the results that until now have been achieved with linear or multiple regressions. Problems in which large amounts of data are available are favorable to the use of neural networks.

In the development of this PhD thesis, three distinct parts are presented.

In the first part, a mobility study is developed based on the data provided by the government, with the aim of finding out how the population moves between the different provinces of Spain. This study can be extrapolated to mobility between any region or area following the same logical steps, but using the appropriate data in each case. This part responds to how the population needs to move between provinces in Spain, that is, the real demand for transport that exists in Spain today. The study has been carried out with government data, obtained from information from cell phone companies. They cover from February 2020 to April 2021, although those corresponding from February to July 2020 were eliminated due to the atypical situation of COVID. Relevant and unknown information is obtained mainly from certain public institutions.

In the second part, for each province and route, the mobility options currently available are presented, comparing the different modes of transport in terms of time and cost. This section deals with how the population can move between provinces in Spain, i.e., the actual supply of transport services available. For each of the provinces, the destinations are analyzed up to 80% of the trips originating in that province. Two fundamental indicators are established: the time (KPI 1) and cost (KPI 2) required to travel 100km on each of the above routes, resulting from the Pareto study.

The above information is very relevant to determine whether the mobility offer is optimal and balanced for all users. It also helps to detect existing imbalances in the supply of public transport on certain routes, so that it must be more competitive in terms of time and cost for the traveler to consider using it. A constant monitoring of these two indicators will lead to an adequate supervision to maintain the existing mobility at the highest possible quality

levels (time, cost, frequency, reliability, availability,...).

In those journeys where the least time and cost is the private car, it means that there is no good public transport service covering that journey. This service does not fulfill its social function.

On routes where rail is more economical and takes less time, an adequate supply is being achieved for the population on that route. It will therefore be easy to encourage the use of public transport in these cases.

The mobility objective of a country like Spain should be to guarantee accessibility to a transport service in which, for any citizen, the cost of traveling 100 km (KPI 1) and the time to travel 100 km (KPI 2) is within a reasonable and equitable range depending on the origin and destination of the trip.

Once these indicators have been evaluated for each trip, it will be easy to determine the range in which they should be maintained, and at the same time to set a goal as a country for the next 5 to 10 years. From this analysis, the most neglected trips that need urgent investment in infrastructure and public transport services will emerge. This result can help prioritize such investments.

In a third part, 5 success cases are presented in which artificial intelligence has helped the optimization of mobility in the railway sector in a concrete way. All the aforementioned stakeholders are involved. This third part answers the question how to optimize to the maximum the material and human resources needed for operation and maintenance, additionally achieving a better matching of supply and demand in terms of transportation.

The first case focuses on the use of neural network models to predict the displacements between two given points. This will help to achieve a better match between the supply and demand of transport services, saving on services with excessively low demand.

The other cases focus on maintenance optimization, implementing the concept of predictive maintenance. Maintenance is essential to ensure safe and reliable operation, while ensuring high availability values. The higher the running speed, the higher the associated maintenance operations and therefore the lower the availability of the infrastructure or rolling stock. In this context, a fundamental task of the sector is to try to minimize preventive maintenance and transform it into predictive maintenance, in order to maximize availability and railway operation, and minimize the associated economic and energy costs.

Among the many components in a train, priority should be given to those that have a direct influence on safety, availability and reliability. A good RAMS analysis must be guaranteed, in accordance with an adequate quality control and guaranteed and regularly monitored safety conditions.

Therefore, 4 cases related to predictive maintenance are studied.

One of the cases focuses on the prediction of degraded conditions due to torrential rains on a bridge, as a direct application of artificial intelligence for predictive maintenance of

infrastructures. In this way, appropriate mitigations and restrictions can be applied to maximize operating conditions.

The other three cases focus on the predictive maintenance of train safety components, which mainly concentrate on the running gear (bearing temperature) and the structure (lateral accelerations of the carbody). Both variables must be maintained in an appropriate range of values, and are considered to be of high safety for train operation. They are monitored in real time with redundant sensors during all runs.

In the case study of accelerations, not only the predictive issue is addressed in order to ensure reliability, availability and safety, but an additional step in the state of the art is taken, and a concept related to user experience is proposed. More specifically, models capable of detecting the degradation of passenger comfort during the ride are determined, detecting a loss of quality with high accuracy, without having to reach the safety levels established by current regulations. In this way, corrective actions can be taken before the detection of the lack of comfort, or before any in-service failure of the main components occurs, leading to speed limitations or service cancellations, with their corresponding penalties and negative consequences.

These success cases, described in different papers, are described in more detail below:

- **Case 1. Prediction of passenger mobility in Spain using neural networks.** Specific routes are chosen and from the data collected by the government, neural network algorithms are applied to predict the future movements of people between two given provinces, obtaining very accurate results in the most frequented routes. The optimal MAE value obtained is 5.38%, so that the predictions are sufficient for the purpose of being able to plan the supply of transport services. This scientific paper is currently under peer review.
- **Case 2. Prediction of anomalous dynamic behavior of a railway bridge with the passage of trains, due to extreme weather conditions..** In this scientific paper, artificial intelligence is used to predict the dynamic response of a railway bridge with the passage of trains under normal conditions, so that an anomalous behavior of the bridge, due to extreme weather conditions such as heavy rains, can be detected. These rains cause restrictions in the operation to ensure maximum safety levels. Early detection of anomalous behavior of the infrastructure avoids incurring operational risks by imposing a series of mitigations well in advance. This is a clear example of optimizing predictive maintenance of railway infrastructure. Recurrent neural networks are used, obtaining a value of 9% of MAE in the optimal model, which widely allows to be able to detect the presence of adverse weather conditions, which put at risk the railway operation. This scientific paper is currently under peer review.
- **Case 3. Prediction of railway bearing failures due to over temperature.** In this scientific paper, several artificial intelligence models based on neural networks are built in order to predict the failure of a railway bearing due to high temperatures. Railway bearings are a safety element and therefore, the temperatures reached in real time during operation must be monitored redundantly. In the event of detecting over-temperatures,

the speed of circulation must be limited, and even the train itself must be stopped with the consequences that this entails. The prediction of this kind of failures helps to optimize the operation and is framed in the context of predictive maintenance of rolling stock, thus avoiding any incident during operation. The neural network of the most optimized model has an accuracy of 99% and a performance of 95%. It is able to predict a bearing failure more than 2 days in advance, which allows to plan a maintenance shutdown with enough time before the potential failure occurs in service. This scientific paper has recently been published in a Q3 scientific journal.

- **Case 4. Predicting degradation of passenger comfort due to deterioration of train damping.** Car body and rolling accelerations are variables that are redundantly collected in trains in order to ensure the safety of the operation. In this paper, a neural network model is created to predict an anomalous behavior of the accelerations of the structure of a high-speed train. The best model presents a MAE of 0.034 m/s^2 . Since the model is trained with many samples that present a normal behavior of the accelerations, when there is an anomalous behavior or a behavior that deviates from the usual one, it is easily detected by the algorithm. With this information, the inspection of the suspension and damping of the train is promoted, since they are the main components related to the dynamics. In this research on predictive maintenance, it is therefore possible to detect the moment when a loss of comfort begins in the train, because the accelerations of the train structure start to behave differently than usual. This study can also be framed within the context of user experience, since comfort is of vital importance for the traveler, and since the loss of comfort is detected long before reaching safety levels due to excessive accelerations in the vehicle. This scientific paper has recently been published in a Q2 scientific journal.
- **Case 5. Prediction of passenger comfort degradation due to train damping deterioration using LSTM (long short - term memory) networks.** This scientific paper pursues the same objective as the previous one, but the difference is that it works with more complex algorithms of the LSTM (long short - term memory) type. These algorithms take into account the time variable through the clustering of ordered samples. In addition, the model output itself is itself the input variable of the next iteration. The optimal time window for sample shaping is determined to be 5 seconds. The optimized model achieves a MAE value of 0.033 m/s^2 , so it successfully detects the degradation of comfort in the train before any damping or suspension failure occurs, which may generate a temporary speed limitation or safety risk. This scientific paper has been published in a Q1 scientific journal recently.

These 5 cases exposed demonstrate the added value of artificial intelligence, although, as discussed in the state of the art, the problems of the sector must be addressed in a cross-cutting manner.

Based on the experience and data analyzed, an estimation is made of a potential saving of 40% of preventive interventions, which can represent a very significant saving over the entire life cycle of a train or an infrastructure. As for the prediction of travel, the benefit will clearly exist for transport services that are decided to be eliminated due to the predicted

low demand. Both savings are not consolidated directly, since it will also require an IT architecture, equipment, sensors and people in charge of continuous monitoring of the data to make the predictions.

As a guideline, the total benefit of the implementation of artificial intelligence, in the above cases, can be summarized by the following formula:

$$A_{et} = \sum 0.5 \cdot C_{pvt} \cdot k_1 + \sum P_f \cdot k_2 + \sum S_a$$

where A_{et} represents the estimated total savings per unit of time (month, quarter, semester or year), C_{pvt} the preventive maintenance costs per time unit, k_1 a correction factor that takes values between 1 – 1.5 in order to absorb inefficiencies and given that there are no stops for preventive maintenance exclusively, k_2 a correction factor for penalties, that takes values between 0.5 – 0.8, since not all of them are due to reliability failures of major components or not always the prediction will be accurate, and S_a represents the services saved by being able to adjust the travel prediction, which in each case and means of transport will have to be specified by the operator.

By grouping the three previous parts that make up the main core of the thesis, a methodology for the optimization of existing mobility applied to the railway sector is finally proposed, which can be extrapolated to any means of transport and can be extended to any area, region or country. It has been baptized as **Transportation**.

It consists of two different phases. In the first phase, the aim is to know the real mobility needs and the existing supply, in order to align supply and demand in the most efficient way possible. The second phase involves optimizing the operation and maintenance of mobility services in order to achieve intelligent, efficient and sustainable mobility.

The steps that make up the methodology are summarized below:

1. To know the real demand for mobility by the population, analyzing travel data that have been collected in a robust and representative manner.
2. Detect 80% of the routes most demanded by the population in each of the regions or areas considered.
3. Analyze the specific data of the different means of transportation offered to the population, in the most relevant routes considered in step 2.
4. Determine the two main indicators (KPIs) mentioned above: the time and cost for a person to travel 100 km on each of these journeys.
5. Agree on the average value that these two indicators should take, and the maximum and minimum tolerable values for a balanced and reasonable transport system for all citizens.

From the above, a priority of works and investments to be carried out in the future will be established, in order to preserve the ranges established for the two previous indicators.

The second phase of the methodology deals with the optimization of economic and energy resources of mobility. The steps established in this second phase are:

6. Analyze the most frequent or relevant mobility problems from the point of view of the operator, infrastructure manager and rolling stock maintainer, in order to prioritize them from a cross-cutting point of view.
7. Analyze the synergies that may exist among stakeholders, sharing resources and information if necessary.
8. Apply artificial intelligence to optimize the solution of the problems studied, using any of the existing algorithms and techniques. The area detected with the greatest potential for energy and economic savings is maintenance, known as predictive maintenance, with the aim of replacing part of the preventive maintenance, both in infrastructure and rolling stock.

This methodology should be applied iteratively to provide continuity and always work with updated information. It is a dynamic methodology. Therefore, a complete and structured model is proposed for the optimization of a mobility system that aims to be intelligent.

It can be applied to a specific means of transport, or to all means of transport in general, depending on the scope to be addressed. It is also applicable both at the national level by studying mobility between provinces, and at the local level by studying data for municipalities or districts. These data are also publicly available on the government's website.

We have worked on a national level between provinces, but in future lines it is recommended to work also on a more local level focused on the recent concept of smart urban mobility. For this, other boundary conditions and means of transport should be taken into account in the study, (metro network, local or regional buses, streetcars, commuter line ...).

Finally, it should be noted that not all political decisions regarding infrastructure investment are made from a purely technical point of view. There are many other factors, subjective in many cases, that influence political decisions.

Therefore, this methodology is intended to be a powerful tool, the result of which is an important input variable to be considered when making a decision on investments to be made in the mobility sector. It can also help to prioritize the areas most susceptible to improvement or with the greatest potential for optimization.

It will also help to develop a global mobility strategy, and a much more adjusted and appropriate planning of the transport services to be offered to the citizen in a municipality, district, region or country.

Resumen

Nos encontramos en una realidad cambiante cada día y llena de retos desde diversos puntos de vista, influenciada además por situaciones no predecibles, como una pandemia o guerras con importantes consecuencias en la sociedad del siglo XXI.

La tecnología está evolucionando más rápido de lo que las empresas o la sociedad son capaces de asimilar. En los próximos años, la gran mayoría de las empresas sufrirán un proceso de transformación digital que les hará ser más competentes, optimizando sus procesos y aumentando la productividad y los resultados, fruto de la implementación de la inteligencia artificial.

La inteligencia artificial se considera punta de lanza del progreso científico y tecnológico, entre otros motivos, por el incremento de la información disponible y su tratamiento. El sector IT se encuentra por lo tanto en auge, y muchas empresas de este sector pretenden desarrollar e implementar modelos y procesos que alcancen la máxima optimización económica, aumentando la competitividad de las compañías.

Las nuevas tecnologías y el crecimiento económico deben ir asociados a la idea de mantener, preservar y mejorar el medioambiente, conduciendo a los distintos países hacia un modelo de sostenibilidad que permita optimizar los recursos energéticos y reducir las emisiones. Con este propósito nacieron los Objetivos de Desarrollo Sostenible, fijados en el marco de la Agenda 2030. La relevancia de estos objetivos va aumentando con el paso de los años, y está presente en la mayor parte de las políticas gubernamentales de los distintos países.

La sociedad también se ve influenciada por la evolución tecnológica y cambio de paradigma. La conciliación familiar y la flexibilidad se ven potenciadas por la aparición del teletrabajo, y las profesiones que permiten asimilar la distancia geográfica. Esto impacta de forma directa en la movilidad de las personas.

Hasta el siglo pasado, se entendía el transporte como el desplazamiento de una persona o una mercancía desde un punto inicial, denominado origen, hasta un punto final, denominado destino. Las mejoras existentes hasta la fecha se centraban, o bien en aumentar la frecuencia y los horarios ofertados, o bien en disminuir los costes asociados para el usuario final. También han ido evolucionando los vehículos empleados fruto del avance tecnológico.

Sin embargo, no se ha estado analizando este servicio de transporte desde una perspectiva global, dado que no se hablaba de eficiencia energética, tasa de accidentalidad, consumo energético, sostenibilidad, adaptación de oferta y demanda, servicios auxiliares al viajero como parte de la experiencia de usuario, combinación de servicios de transporte, ... Todo ello conlleva a evolucionar el tradicional concepto de transporte al concepto de movilidad.

En el ámbito de las mercancías, se pretende aumentar el transporte por ferrocarril, disminuyendo el transporte por carretera debido al alto impacto medioambiental que supone. En cuanto al transporte de viajeros, ya se empiezan a limitar los transportes aéreos en zonas regionales o nacionales.

Un objetivo claro es además disminuir el uso del automóvil particular, y descargar más las carreteras tanto en el ámbito urbano como en el interurbano. Esto se conoce como descarbonización del transporte. Para ello, se debe continuar en paralelo potenciando el transporte público mediante el ferrocarril, acompañando a la necesidad creciente de priorizarlo por motivos energéticos, de sostenibilidad y de eficiencia tanto económica como energética.

A nivel europeo, se viene estudiando en detalle la clara apuesta por el sector ferroviario como medio de transporte preferido, a través de la Empresa Común *Europe's Rail*, (*EU-Rail*).

El objetivo de *EU-Rail* es promover una red ferroviaria europea integrada de alta capacidad eliminando las dificultades provenientes de la interoperabilidad, ofreciendo soluciones para la plena integración (gestión del tráfico, vehículos, infraestructuras y servicios) y logrando una adopción y un despliegue más rápidos de las innovaciones a través de proyectos financiados. *EU-Rail* apuesta por el empleo de la digitalización y la automatización para reducir los costes de la industria ferroviaria, aumentar la capacidad y reforzar la flexibilidad y la fiabilidad.

Los objetivos de *EU-Rail* están alineados con la política de UE en cuanto a la visión de la industria ferroviaria y los retos inherentes a la transformación del sistema ferroviario. Es fundamental responder a las exigencias cambiantes de los usuarios, mejorar el rendimiento y la capacidad, reducir los costes, contribuir a un transporte más sostenible, ofrecer un enfoque armonizado de la adaptación a los cambios en la industria, conceder un papel más importante al ferrocarril en el transporte y los viajes europeos, y contribuir a una mayor competitividad de la industria de suministros ferroviarios de la UE.

A pesar de trabajar en las mejoras mencionadas, hay todavía una serie de retos que abordar en los próximos años, relacionados con la movilidad. Se pueden clasificar en dos categorías: resolución de problemas conocidos hoy en día, y retos futuros que derivarán de la evolución de la tecnología aplicada al sector del transporte.

En cuanto a los retos existentes, cabe destacar la importancia de optimizar la oferta y la demanda de transporte empleando la inteligencia artificial como herramienta prioritaria, incluyendo la aplicación en todo el ciclo global de operación, con objeto de optimizar los recursos económicos y humanos destinados a los servicios de transporte. Esto dará lugar a una implementación real de la industria 4.0 en el sector del transporte, y ayudará, sin duda, a ir equilibrando los costes y tiempos de transporte de todos los ciudadanos dentro de una horquilla razonable. Es necesario asegurar la accesibilidad a una red de transporte fiable y completa a todos los ciudadanos, dado que existen regiones despobladas o de difícil acceso que impiden un progreso adecuado de dichas poblaciones, tanto a nivel económico como a nivel social.

Mirando hacia el futuro, la evolución tecnológica continuará conformando un nuevo enfoque de movilidad, con nuevos planteamientos que conviene ir investigando. Por ejemplo, la evolución de los vehículos eléctricos, o a la aparición de la tecnología de hidrógeno u otra tecnología alternativa de tracción, influirán de forma directa en la infraestructura y organización del sector del transporte.

Se está investigando actualmente en el modelo de compartición de vehículos, generando un

modelo de gestión de flotas similar al ya existente en el sector público (por ejemplo, con los autobuses).

Con la aparición de diversas compañías privadas de alquiler de vehículos eléctricos, se analizará durante los próximos años la posibilidad de cargar la batería en marcha, o incluso poder cargar un vehículo con otro vehículo que esté en circulación, en concepto de compartición de energía entre la propia flota de vehículos.

El futuro del transporte todavía es muy incierto, si bien es cierto que la optimización de recursos económicos y energéticos siempre será una labor fundamental en el sector.

Hoy en día, la inteligencia artificial es la que ayuda principalmente en esta labor de mejora de la movilidad existente. Es conveniente estudiar los datos de los desplazamientos de las personas y de las mercancías, para compararlo con las necesidades reales, y poder adaptar más fácilmente la oferta y la demanda de los servicios de transporte.

Además, el empleo de la inteligencia artificial colabora en la optimización de la operación y mantenimiento, tanto de la infraestructura como de los vehículos, alcanzando mayores tasas de disponibilidad y fiabilidad con el menor número posible de recursos invertidos.

Esta tesis doctoral se centra en la creación de una metodología para la optimización de la movilidad existente en el sector ferroviario, siendo posible extrapolarlo a los demás medios de transporte y a cualquier escala geográfica, con el fin de obtener una visión más completa.

Esta metodología propone en una de las fases el empleo de la inteligencia artificial, como herramienta fundamental para la optimización la movilidad ferroviaria de viajeros como caso particular de aplicación.

En el sector ferroviario, intervienen tres grupos de interés principalmente: el operador, el administrador de la infraestructura, y el fabricante y mantenedor del material rodante.

Normalmente son compañías diferentes, por lo que se hace complicado trabajar en un problema desde un punto de vista general, debido a que cada uno trata de optimizar su parcela sin tener en cuenta los otros grupos de interés. Esto genera soluciones optimizadas de forma aislada (extremos relativos), pero no una solución global óptima para el sector en su conjunto (extremos absolutos).

Adicionalmente, con el creciente volumen de datos que se recogen de los trenes o de la infraestructura, se continúa sin compartir información entre las distintas compañías para poder generar valor añadido al transporte ferroviario. De forma progresiva es conveniente cambiar esta tendencia, para poder trabajar en soluciones potencialmente beneficiosas para el sector en general. Los datos deben compartirse con el buen propósito de encontrar la mejora continua y la optimización global que beneficie a todas las partes.

Se ha realizado un estudio del estado del arte, en base a 72 artículos de investigación relacionados con la aplicación de las nuevas tecnologías y la inteligencia artificial, en los tres principales grupos de interés de la movilidad ferroviaria.

Como conclusión general puede observarse que tan solo el 9% de los artículos tratan temáticas incorporando a todos los grupos de interés, siendo más del 50% de los casos en los que únicamente uno de los participantes interviene en el tratamiento y resolución de la problemática expuesta.

Esto demuestra que no se están tratando de forma transversal los problemas y retos existentes relacionados con la movilidad ferroviaria, y por tanto esta visión sesgada y no compartida, genera soluciones parciales que se alejan de alcanzar el óptimo para todas las partes involucradas. Existe un amplio campo de mejora en materia de análisis y resolución de problemas, y es uno de los puntos clave que trata de resolver la metodología de esta tesis doctoral.

Las temáticas principales de estos artículos estudiados giran en torno a la seguridad, a la fiabilidad y mantenimiento, a la sostenibilidad y a la experiencia de usuario. Más de la mitad de los artículos estudiados tratan sobre la optimización y mejora de la fiabilidad y la mantenibilidad, alineado con lo expuesto en los antecedentes, relativo a la necesidad creciente de investigar este campo para conseguir mejorar notablemente la eficiencia de la operación ferroviaria de viajeros y mercancías. El segundo campo más estudiado es la seguridad, con intención de seguir optimizando y mejorando esta área para reducir los riesgos y la responsabilidad por errores humanos.

Los problemas mayormente estudiados son los relativos a la detección de obstáculos en la vía y el mantenimiento predictivo, tanto de infraestructura como de material rodante. Otra línea de investigación existente, está relacionada con la redundancia y automatización de supervisiones de seguridad empleando las nuevas tecnologías. La sostenibilidad y la experiencia de usuario son campos en los que la investigación está empezando a potenciarse, y tiene todavía un amplio recorrido de estudio y aplicación futura. Otras temáticas como la ciberseguridad y las comunicaciones son, y seguirán siendo de interés en el futuro, dado la constante evolución de la tecnología.

Desde el punto de vista matemático, el *deep learning* es una de las técnicas de inteligencia artificial más aplicadas en los distintos artículos analizados. Las redes neuronales presentan de forma general unos resultados muy positivos, esto es, con una baja tasa de error, y una eficacia suficiente para la resolución de distintos problemas de clasificación o de regresión. Estos algoritmos presentan una parte de cálculo lineal y otra de cálculo no lineal, que logran mejorar los resultados que hasta ahora se venían consiguiendo con regresiones lineales o múltiples. Problemas en los que existen grandes cantidades de datos disponibles, son favorables al uso de las redes neuronales.

En el desarrollo de esta tesis doctoral, se presentan tres partes bien diferenciadas.

En una primera parte, se desarrolla un estudio de movilidad realizado a partir de los datos aportados por el gobierno, con objeto de conocer cómo se mueve la población entre las distintas provincias de España. Este estudio se puede extrapolar a la movilidad entre cualquier región o área siguiendo los mismos pasos lógicos, pero empleando los datos adecuados en cada caso. Esta parte responde a **cómo necesita moverse** la población entre provincias en España, esto es, la demanda real de transporte que existe en España hoy en día. El estudio se ha realizado con los datos del gobierno, obtenidos a partir de la información de las compañías de

telefonía móvil. Comprenden desde febrero del año 2020 hasta abril del año 2021, aunque se eliminaron los correspondientes desde febrero hasta julio de 2020 debido a la situación atípica del COVID. Se obtiene información relevante y desconocida mayormente por parte de ciertas instituciones públicas.

En una segunda parte, se exponen para cada provincia y trayecto las opciones de movilidad existentes en la actualidad, comparando los distintos modos de transporte en términos de tiempos y costes. Este apartado responde a **cómo puede moverse** la población entre provincias de España, esto es, la oferta real de los servicios de transporte que existe. Para cada una de las provincias, se analizan los destinos hasta alcanzar el 80% de los viajes con origen en dicha provincia. Se establecen dos indicadores fundamentales: el tiempo (KPI 1) y el coste (KPI 2) necesarios para recorrer 100km en cada uno de los trayectos anteriores, resultantes del estudio de Pareto.

La información anterior es muy relevante para determinar si la oferta de movilidad es óptima y está equilibrada para todos los usuarios. También ayuda a detectar desequilibrios existentes en la oferta del transporte público en ciertos trayectos, de tal forma que deba ser más competitivo en materia de tiempos y costes para que el viajero se pueda plantear usarlo. Una monitorización constante de estos dos indicadores, dará lugar a una supervisión adecuada para mantener la movilidad existente en los máximos niveles de calidad posibles (tiempo, coste, frecuencia, fiabilidad, disponibilidad,...).

En los trayectos en los que el menor tiempo y coste resulta ser el coche particular, significa que no existe un buen servicio de transporte público que cubra dicho trayecto. No cumple este servicio su labor social.

En los trayectos en los que el ferrocarril sea más económico y tarde menos tiempo, se está consiguiendo una oferta adecuada para la población en ese trayecto. Será por tanto sencillo fomentar el uso del transporte público en estos casos.

El objetivo en materia de movilidad de un país como España, debe ser garantizar la accesibilidad a un servicio de transporte en el que, a cualquier ciudadano, el coste de recorrer 100 km (KPI 1) y el tiempo para recorrer 100 km (KPI 2), se encuentre dentro de una horquilla razonable y equitativa en función del origen y destino de su desplazamiento.

Una vez evaluados esos indicadores en cada desplazamiento, será sencillo determinar el intervalo en el que deben mantenerse, y paralelamente fijar un objetivo como país de cara a los próximos 5 ó 10 años. A partir de este análisis, saldrán a la luz los desplazamientos más desatendidos, que necesiten de una inversión urgente en infraestructura y en servicios de transporte público. Este resultado puede ayudar a priorizar dichas inversiones.

En una tercera parte, se presentan 5 casos de éxito en los cuales la inteligencia artificial ha ayudado a la optimización de la movilidad en el sector ferroviario de forma concreta. Se involucran a todos los grupos de interés mencionados. Esta tercera parte responde a la pregunta **cómo optimizar al máximo** los recursos materiales y humanos necesarios para la operación y el mantenimiento, logrando adicionalmente una mejor adaptación de la oferta y la demanda en cuanto al transporte se refiere.

El primer caso, se centra en el uso de modelos de redes neuronales para predecir los desplazamientos existentes entre dos puntos determinados. Esto ayudará a alcanzar un mayor ajuste de la oferta y la demanda de los servicios de transporte, pudiendo ahorrarse aquellos servicios con una demanda excesivamente baja.

Los demás casos, se centran en la optimización del mantenimiento, implementando el concepto de mantenimiento predictivo. El mantenimiento es fundamental para garantizar una operación segura y fiable, asegurando a su vez altos valores de disponibilidad. A mayor velocidad de circulación, mayores operaciones de mantenimiento asociadas y por tanto menos disponibilidad de la infraestructura o del material rodante. En este contexto, una labor fundamental del sector es tratar de minimizar los mantenimientos preventivos, e ir transformándolos en predictivos, con objeto de maximizar la disponibilidad y la operación ferroviaria, y minimizar los costes económicos y energéticos asociados.

Dentro de los múltiples componentes existentes en un tren, se debe trabajar de forma prioritaria en aquellos que tienen una influencia directa en seguridad, disponibilidad y fiabilidad. Se debe garantizar un buen análisis RAMS, acorde con un control de calidad adecuado y unas condiciones de seguridad garantizadas y supervisadas de forma periódica.

Se estudian, por tanto, 4 casos relacionados con el mantenimiento predictivo.

Uno de los casos, se centra en la predicción de condiciones degradadas debido a lluvias torrenciales en un puente, como aplicación directa de la inteligencia artificial para el mantenimiento predictivo de las infraestructuras. De este modo se podrán aplicar las mitigaciones y restricciones oportunas para maximizar las condiciones de operación.

Los otros tres casos, se centran en el mantenimiento predictivo de componentes de seguridad del tren, que principalmente se concentran en la rodadura (temperatura de rodamientos) y en la estructura (aceleraciones transversales de la caja). Ambas variables deben mantenerse en un rango apropiado de valores, y se consideran de alta seguridad para la operación del tren. Se supervisan en tiempo real con sensores redundantes durante todos los trayectos.

En el caso de estudio de las aceleraciones, no solo se trata el tema predictivo con objeto de garantizar la fiabilidad, disponibilidad y seguridad, sino que se da un paso adicional en el estado del arte, y se propone un concepto relacionado con la experiencia de usuario. Más concretamente, se determinan modelos capaces de detectar la degradación del confort del viajero durante la marcha, detectando una pérdida de calidad con alta precisión, sin tener que alcanzar los niveles de seguridad establecidos por la normativa vigente. De este modo, se podrán tomar acciones correctivas antes de la detección de la falta de confort, o antes de que ocurra cualquier fallo en servicio de los componentes principales, dando lugar a limitaciones de velocidad o cancelaciones de servicio, con sus correspondientes penalizaciones y consecuencias negativas.

Estos casos de éxito, presentados en diferentes artículos de investigación, se describen a continuación de forma más concreta:

- **Caso 1. Predicción de la movilidad de viajeros en España empleando redes**

neuronales. Se escogen unas rutas concretas y a partir de los datos recopilados por el gobierno, se aplican algoritmos de redes neuronales para predecir a futuro los desplazamientos de las personas entre dos provincias dadas, obteniendo resultados muy precisos en las rutas más frecuentadas. El valor óptimo de MAE obtenido es de 5.38%, por lo que las predicciones son suficientes para el propósito de poder planificar la oferta de los servicios de transporte. Este artículo científico se muestra actualmente en revisión (peer review).

- **Caso 2. Predicción de comportamiento dinámico anómalo de un puente ferroviario con el paso de los trenes, debido a condiciones climatológicas extremas.** En este artículo científico, se emplea la inteligencia artificial para predecir la respuesta dinámica de un puente ferroviario con el paso de los trenes en condiciones normales, de tal forma que pueda detectarse un comportamiento anómalo del mismo, debido a condiciones climatológicas extremas como fuertes lluvias. Estas lluvias provocan restricciones en la operación para garantizar los máximos niveles de seguridad. La detección temprana de un comportamiento anómalo de la infraestructura evita incurrir en riesgos de operación, imponiendo una serie de mitigaciones con suficiente antelación. Es un claro ejemplo de optimización del mantenimiento predictivo de la infraestructura ferroviaria. Se emplean redes neuronales recurrentes, obteniendo un valor de 9% de MAE en el modelo óptimo, lo cual permite ampliamente poder detectar la presencia de condiciones climáticas adversas, que pongan en riesgo la operación ferroviaria. Este artículo científico se muestra actualmente en revisión (peer review).
- **Caso 3. Predicción de fallos de rodamientos ferroviarios por sobre temperatura.** En este artículo científico se construyen diversos modelos de inteligencia artificial basados en redes neuronales, con objeto de predecir el fallo de un rodamiento ferroviario por altas temperaturas. Los rodamientos ferroviarios son un elemento de seguridad y por tanto, se debe monitorizar de forma redundante las temperaturas que alcanzan en tiempo real durante la operación. En caso de detectar sobre temperaturas debe limitarse la velocidad de circulación, e incluso detener el propio tren con las consecuencias que ello conlleva. La predicción de esta clase de fallos, ayuda a optimizar la operación y se enmarca en el contexto de mantenimiento predictivo del material rodante, evitando así cualquier incidente durante la operación. La red neuronal del modelo más optimizado presenta una precisión de 99%, y un rendimiento del 95%. Se consigue predecir un fallo de un rodamiento con más de 2 días de antelación, lo cual permite poder planificar con tiempo suficiente una parada en mantenimiento antes, de que se produzca el potencial fallo en servicio. Este artículo científico ha sido publicado recientemente en una revista científica Q3.
- **Caso 4. Predicción de la degradación del confort del viajero por deterioro de la amortiguación del tren.** Las aceleraciones de la caja y de la rodadura son variables que se recogen de forma redundante en los trenes, de cara a garantizar la seguridad de la operación. En este artículo se crea un modelo de redes neuronales, para predecir un comportamiento anómalo de las aceleraciones de la estructura de un tren de alta velocidad. El mejor modelo presenta un MAE de 0.034 m/s^2 . Dado que el modelo se entrena con muchos trayectos que presentan un comportamiento normal de

las aceleraciones, al existir un comportamiento anómalo o que se aleja del habitual, es detectado fácilmente por el algoritmo. Con esta información, se promueve la inspección de la suspensión y la amortiguación del tren, dado que son los componentes principales relacionados con la dinámica. En este artículo sobre el mantenimiento predictivo, se logra por tanto detectar el momento en el que comienza una pérdida de confort en el tren, porque las aceleraciones de la estructura del tren pasan a comportarse de manera distinta a la habitual. Este estudio también se puede enmarcar dentro del contexto de experiencia de usuario, al ser el confort de vital importancia para el viajero, y dado que la pérdida de confort se detecta mucho antes de alcanzar niveles de seguridad por aceleraciones excesivas en el vehículo. Este artículo científico se ha publicado en una revista científica Q2 recientemente.

- **Caso 5. Predicción de la degradación del confort del viajero por deterioro de la amortiguación del tren empleando redes *LSTM* (*long short – term memory*).** Este artículo científico persigue el mismo objetivo que el anterior, pero la diferencia es que trabaja con algoritmos más complejos del tipo *LSTM* (*long short – term memory*). Estos algoritmos tienen en cuenta la variable temporal a través de la agrupación de muestras ordenadas. Además, la propia salida del modelo es a su vez variable de entrada de la siguiente iteración. Se determina que la ventana óptima de tiempo para conformar las muestras es de 5 segundos. El modelo optimizado alcanza un valor de MAE de 0.033 m/s^2 , por lo que detecta satisfactoriamente la degradación del confort en el tren antes de que se produzca cualquier fallo en la amortiguación o suspensión, que pueda genera una limitación temporal de velocidad o un riesgo de seguridad. Este artículo científico se ha publicado en una revista científica Q1 recientemente.

Los casos estudiados demuestran el valor añadido que aporta la inteligencia artificial, aunque como se ha analizado en el estado del arte, deben afrontarse los problemas del sector de forma transversal.

En base a la experiencia y los datos analizados, se hace una estimación de un potencial ahorro del 40% de las intervenciones preventivas, lo cual puede suponer un ahorro muy importante a lo largo de todo el ciclo de vida de un tren o de una infraestructura. En cuanto a la predicción de los desplazamientos, el beneficio claramente existirá por los servicios de transporte que se decidan suprimir por la baja demanda predicha. Ambos ahorros no se consolidan en el acto, dado que por otro lado requerirá una arquitectura de IT, equipos, sensores y personas encargadas de la supervisión continua de los datos para realizar las predicciones.

A título orientativo, se puede resumir el beneficio total de la implementación de la inteligencia artificial, en los casos expuestos, mediante la siguiente fórmula:

$$A_{et} = \sum 0.5 \cdot C_{pvt} \cdot k_1 + \sum P_f \cdot k_2 + \sum S_a$$

donde A_{et} representa el ahorro estimado total por unidad de tiempo (mes, trimestre, semestre o año), C_{pvt} los costes de mantenimiento preventivo por unidad de tiempo, k_1 un factor corrector que toma valores entre 1 – 1.5 con objeto de absorber ineficiencias y dado que no existen paradas para manenimiento preventivo de forma exclusiva, k_2 un factor corrector

de penalizaciones, que toma valores entre 0.5 – 0.8, dado que no todas se deben a fallos de fiabilidad de componentes principales o no siempre la predicción será exacta, y S_a representa los servicios ahorrados por poder ajustar la predicción de los desplazamientos, que en cada caso y medio de transporte deberá ser especificado por el operador.

Agrupando las tres partes anteriores que conforman el núcleo principal de las tesis, se propone finalmente una metodología para la optimización de la movilidad existente aplicado al sector ferroviario, extrapolable a cualquier medio de transporte y extensible a cualquier área, región o país. Se ha bautizado como **Transportation**.

Está formada por dos fases diferenciadas. En la primera fase se pretende conocer las necesidades reales de movilidad y la oferta existente, de cara a poder alinear oferta y demanda de la forma más eficiente posible. En la segunda fase entra en juego la optimización de la operación y mantenimiento de los servicios de movilidad con objeto de alcanzar una movilidad inteligente, eficiente y sostenible.

Los pasos que conforman la metodología se resumen a continuación:

1. Conocer la demanda real de movilidad por parte de la población, analizando datos de desplazamiento que se hayan recogido de una manera robusta y que sean representativos.
2. Detectar el 80% de los trayectos más demandados por la población en cada una de las regiones o áreas de estudio.
3. Analizar los datos concretos de los distintos medios de transporte ofertados a la población, en los trayectos más relevantes considerados en el paso 2.
4. Determinar los dos indicadores principales (KPI) mencionados: el tiempo y el coste que supone recorrer 100 km a una persona en cada uno de esos trayectos.
5. Acordar el valor medio que deben tomar estos dos indicadores, y los valores máximos y mínimos tolerables para un sistema de transportes equilibrado y razonable para todos los ciudadanos.

De lo anterior, saldrá una prioridad de trabajos e inversiones a realizar a futuro, con objeto de preservar los rangos establecidos para los dos indicadores anteriores.

En una segunda fase de la metodología, se trata la optimización de recursos económicos y energéticos de la movilidad. Los pasos establecidos en esta segunda fase son:

6. Analizar los problemas más frecuentes o relevantes de la movilidad desde el punto de vista del operador, gestor de la infraestructura y mantenedor de material rodante, con objeto de priorizarlos desde un punto de vista transversal.
7. Analizar las sinergias que puede haber entre las partes interesadas, compartiendo recursos e información si fuera necesario.
8. Aplicar la inteligencia artificial para optimizar la solución de los problemas estudiados, mediante cualquiera de los algoritmos y técnicas existentes. El área detectada con un

mayor potencial ahorro energético y económico es el del mantenimiento, conocido como mantenimiento predictivo, con objeto de ir reemplazando parte del preventivo, tanto en infraestructuras como en material rodante.

Esta metodología debe aplicarse de forma iterativa para darle continuidad y trabajar siempre con información actualizada. Se trata de una metodología dinámica. Se propone por tanto un modelo completo y estructurado para la optimización de un sistema de movilidad que pretende ser inteligente.

Se puede aplicar a un medio de transporte concreto, o a todos los medios de transporte en general, en función del alcance que se desee abordar. También es de aplicación tanto en el ámbito nacional estudiando la movilidad entre provincias, como a nivel local estudiando los datos de municipios o distritos. Dichos datos también son de acceso público en la página web del gobierno.

Se ha trabajado en un ámbito nacional entre provincias, pero en las líneas futuras se recomienda trabajar también en un ámbito más local enfocado al reciente concepto de movilidad urbana inteligente. Para ello deben tenerse en cuenta otras condiciones de contorno y medios de transporte en el estudio, (red de metro, autobuses locales o regionales, tranvías, línea de cercanías ...).

Para terminar, cabe destacar que no todas las decisiones políticas, en cuanto a inversión de infraestructuras se refiere, se toman desde un punto de vista meramente técnico. Existen otros muchos factores, subjetivos en muchos de los casos, que influyen en las decisiones políticas.

Por ello, esta metodología pretende ser una herramienta potente, cuyo resultado sea una variable de entrada importante a considerar a la hora de tomar una decisión sobre las inversiones a realizar en el sector de la movilidad. Puede ayudar, además, a priorizar las áreas más susceptibles de mejora o que mayor potencial de optimización presentan.

Asimismo, ayudará a elaborar una estrategia global de movilidad, y una planificación mucho más ajustada y apropiada de los servicios de transporte a ofrecer al ciudadano en un municipio, distrito, región o país.

Tabla de Contenido

Agradecimientos	v
Abstract	vi
Resumen	xv
Lista de Figuras	xxvii
Lista de Tablas	xxxix
Abreviaturas y acrónimos	xxxv
1 Introducción	1
1.1 Evolución de la tecnología	2
1.2 Sostenibilidad y Agenda 2030	4
1.3 Evolución del concepto de movilidad	6
1.3.1 Movilidad del pasado	6
1.3.2 Movilidad del presente	6
1.3.3 Movilidad del futuro	9
2 Estado del arte	13
2.1 Antecedentes de la movilidad en Europa	13
2.1.1 Evolución del transporte de viajeros y mercancías	14
2.1.2 Prestaciones demandadas a los servicios de transporte	24
2.1.3 EU-Rail	28
2.2 Aplicaciones de la inteligencia artificial a la movilidad ferroviaria	30
3 Objetivos y metodología	45
3.1 Objetivos	45
3.2 Metodología	46
4 Resultados y discusión	49
4.1 Estudio de la movilidad entre provincias de España (demanda)	51
4.1.1 Descripción de los datos empleados en el estudio	51
4.1.2 Datos de la movilidad entre provincias (demanda)	54
4.2 Servicios de transporte entre provincias de España (oferta)	62
4.3 Optimización de la movilidad para adaptar oferta y demanda	70
4.3.1 Caso 1. Predicción de la movilidad de viajeros en España empleando redes neuronales.	72
Objetivo	72

	Base teórica	73
	Modelos y resultados	76
	Conclusiones	81
4.3.2	Caso 2. Predicción de comportamiento dinámico anómalo de un puente ferroviario con el paso de los trenes debido a condiciones climatológicas extremas.	82
	Objetivo	82
	Base teórica	82
	Metodología seguida	85
	Desarrollo de la metodología	85
	Limpieza de datos	93
	Modelo de <i>Random Forest</i> y resultados	94
	Modelo de red neuronal recurrente	97
	Conclusiones	102
4.3.3	Caso 3. Predicción de fallos de rodamientos ferroviarios por altas temperaturas.	103
	Objetivo	103
	Metodología	104
	Modelos y resultados	107
	Modelo final optimizado	107
	Conclusiones	108
4.3.4	Caso 4. Predicción de la degradación del confort del viajero por deterioro de la amortiguación del tren	110
	Objetivo	110
	Datos y definición del modelo	111
4.3.5	Modelos y resultados	114
4.3.6	Caso real aplicado del algoritmo	116
	Conclusiones	119
4.3.7	Caso 5. Predicción de la degradación del confort del viajero por deterioro de la amortiguación del tren, empleando redes <i>LSTM</i>	121
	Base teórica	122
4.3.8	Limpieza y preparación de los datos	124
4.3.9	Definición de modelos	125
	Resultados	127
	Comparativa con el modelo anterior	128
	Caso real aplicado del algoritmo	130
	Conclusiones	131
4.4	Discusión de los resultados y proposición de la metodología de optimización de la movilidad futura.	132
4.4.1	Fase 1	134
5	Conclusiones y líneas futuras	139
5.1	Conclusiones principales.	139
5.1.1	Conclusiones de la evolución del transporte en España.	139
5.1.2	Conclusiones del estudio de movilidad entre provincias (demanda) . .	141

5.1.3	Conclusiones del servicio de transporte entre provincias (oferta) . . .	142
5.1.4	Conclusiones de la optimización de la movilidad existente	143
5.2	Líneas futuras de investigación	146
5.2.1	Implantación real de la metodología entre provincias.	147
5.2.2	Futuras investigaciones acerca de la metodología.	147
Referencias		151
Anexos		165

Lista de Figuras

1.1	Objetivos de Desarrollo Sostenible.	5
1.2	Comparación de las emisiones medias de los distintos medios de transporte. .	9
2.1	Evolución total del transporte de viajeros y mercancías tanto en España como a nivel internacional.	14
2.2	Evolución del transporte de viajeros a nivel nacional.	15
2.3	Evolución del transporte de viajeros a nivel internacional.	15
2.4	Evolución del transporte de mercancías a nivel nacional.	15
2.5	Evolución del transporte de mercancías a nivel internacional.	15
2.6	Evolución del transporte ferroviario de viajeros a nivel nacional.	16
2.7	Evolución del transporte por carretera de viajeros a nivel nacional.	16
2.8	Evolución del transporte aéreo de viajeros a nivel nacional.	17
2.9	Evolución del transporte marítimo de viajeros a nivel nacional.	17
2.10	Evolución del transporte ferroviario de viajeros a nivel internacional.	17
2.11	Evolución del transporte por carretera de viajeros a nivel internacional. . . .	17
2.12	Evolución del transporte aéreo de viajeros a nivel internacional.	18
2.13	Evolución del transporte marítimo de viajeros a nivel internacional.	18
2.14	Evolución del transporte ferroviario de mercancías a nivel nacional.	18
2.15	Evolución del transporte por carretera de mercancías a nivel nacional.	19
2.16	Evolución del transporte aéreo de mercancías a nivel nacional.	19
2.17	Evolución del transporte marítimo de mercancías a nivel nacional.	19
2.18	Evolución del transporte ferroviario de mercancías a nivel internacional. . . .	20
2.19	Evolución del transporte por carretera de mercancías a nivel internacional. .	20
2.20	Evolución del transporte aéreo de mercancías a nivel internacional.	20
2.21	Evolución del transporte marítimo de mercancías a nivel internacional. . . .	20
2.22	Evolución del transporte ferroviario de mercancías y viajeros a nivel nacional e internacional.	24
2.23	Ciclo de vida RAMS de acuerdo con la EN – 50126.	28
2.24	Clasificación de los 72 artículos estudiados en función de la temática global tratada.	35
2.25	Diagrama de Pareto de los problemas tratados en los artículos estudiados. . .	38
2.26	Diagrama de la cantidad de grupos de interés que intervienen en cada artículo estudiado.	42

2.27	Artículos clasificados por los grupos de interés concretos que intervienen en cada caso de estudio.	43
4.1	Diagrama de los tres bloques lógicos de la metodología de movilidad inteligente propuesta.	51
4.2	Datos de los archivos <i>Maestra 1 - Distrito</i> de los datos del MITMA (“Open Data Movilidad Ministerio de Transportes, Movilidad y Agenda Urbana”, s.f.-b).	52
4.3	Datos de los archivos <i>Maestra 1 – Municipios</i> de los datos del MITMA (“Open Data Movilidad Ministerio de Transportes, Movilidad y Agenda Urbana”, s.f.-b).	53
4.4	Datos de los archivos <i>Maestra 2 – Distritos</i> de los datos del MITMA (“Open Data Movilidad Ministerio de Transportes, Movilidad y Agenda Urbana”, s.f.-b).	53
4.5	Datos de los archivos <i>Maestra 2 – Municipios</i> de los datos del MITMA (“Open Data Movilidad Ministerio de Transportes, Movilidad y Agenda Urbana”, s.f.-b).	53
4.6	Mapa de calor del porcentaje de desplazamientos desde Madrid a otras provincias.	56
4.7	Mapa de calor del porcentaje de desplazamientos desde Barcelona a otras provincias.	57
4.8	Mapa de calor del porcentaje de desplazamientos desde Jaén a otras provincias.	58
4.9	Mapa de calor del porcentaje de desplazamientos desde Cuenca a otras provincias.	59
4.10	Mapa de calor del porcentaje de desplazamientos desde Toledo a otras provincias.	60
4.11	Mapa de calor del porcentaje de desplazamientos desde Valencia a otras provincias.	61
4.12	Localización del 80 % de los desplazamientos con origen en Madrid.	62
4.13	Estructura de una red neuronal artificial (<i>ANN</i>).	74
4.14	Estructura de una neurona.	74
4.15	Ajuste de las predicciones frente a una regresión lineal.	78
4.16	Ajuste de las predicciones frente a una regresión lineal.	81
4.17	Diagrama simplificado de un modelo de Random Forest.	83
4.18	Diagrama de flujo de la metodología propuesta.	86
4.19	Fase 1 de la metodología propuesta.	87
4.20	Fase 2 de la metodología propuesta.	88
4.21	Fase 3 de la metodología propuesta.	89
4.22	Estructura principal del puente.	90
4.23	Diagrama de los sensores instalados.	91
4.24	Puente sensorizado y estudiado en este artículo.	92
4.25	Mapa de calor de la correlación lineal de la variable.	94
4.26	Fase 1 de la metodología (modelo de <i>Random Forest</i>)	95
4.27	Fase 1 de la metodología <i>SHAP</i>	96
4.28	Concepto de la Fase 2 de la metodología.	97
4.29	Valores reales versus valores predichos en el modelo <i>RNN</i> optimizado de S2.	99
4.30	Valores reales versus valores predichos en el modelo <i>RNN</i> optimizado de S7.	100
4.31	Valores reales versus valores predichos en el modelo <i>RNN</i> optimizado de S8.	100
4.32	Zonas de seguridad y valores límite o umbrales establecidos.	101

4.33	Diferencia entre los valores predichos de S1 (azul) vs los valores reales (amarillo).	102
4.34	Distribución de rodamientos y sensores en un eje del tren.	105
4.35	Modelo 5: Coste de las iteraciones, resultados del conjunto de entrenamiento, resultados del conjunto de validación.	108
4.36	Temperaturas de los rodamientos en grados centígrados a lo largo del tiempo.	111
4.37	Aceleraciones laterales y verticales (m/sr) a lo largo del tiempo.	112
4.38	Aceleraciones laterales y verticales (m/s^2) a lo largo del tiempo.	112
4.39	Ubicación del sensor de aceleración en los coches.	113
4.40	Aceleraciones laterales del coche (eje vertical) del eje número 5 versus el tiempo (eje horizontal): valores reales en azul y valores predichos en rojo.	119
4.41	Aceleraciones laterales del coche (eje vertical) del eje número 11 versus el tiempo (eje horizontal): valores reales en azul y valores predichos en rojo. . .	119
4.42	Estructura de una red neuronal recurrente tipo <i>LSTM</i>	123
4.43	Estructura de la celda <i>LSTM</i> cerrada.	124
4.44	Distribución de los datos.	125
4.45	Comparación de desempeño entre el modelo del caso 4 y los modelos desarrollados en este artículo (Eje 5).	128
4.46	Comparación de desempeño entre el modelo del caso 4 y los modelos desarrollados en este artículo (Eje 1).	129
4.47	Diferencia entre los valores de aceleración lateral previstos (a_{yc}) y los valores de aceleración lateral reales.	131
4.48	Diagrama de flujo de la metodología de optimización de la movilidad existente.	137

Lista de Tablas

1.1	Comparación de las emisiones medias de los distintos medios de transporte. .	8
2.1	Conclusiones principales sobre el transporte de viajeros y mercancías tanto a nivel nacional como a nivel internacional.	21
2.2	Resumen de las tendencias de la evolución del transporte de viajeros tanto a nivel nacional como a nivel internacional desde el 2007 hasta la llegada de la pandemia en 2019.	21
2.3	Resumen de las tendencias de la evolución del transporte de viajeros tanto a nivel nacional como a nivel internacional desde el 2007 hasta los datos más actuales del 2021.	21
2.4	Resumen de las tendencias de la evolución del transporte de viajeros tanto a nivel nacional como a nivel internacional por modo de transporte.	22
2.5	Resumen de las tendencias de la evolución del transporte de mercancías tanto a nivel nacional como a nivel internacional por modo de transporte.	22
2.6	Resumen de los indicadores de la evolución del transporte de viajeros y mercancías tanto a nivel nacional como a nivel internacional en el año 2019 por modo de transporte.	22
2.7	Resumen de los indicadores de la evolución del transporte de viajeros y mercancías tanto a nivel nacional como a nivel internacional en el año 2021 por modo de transporte.	23
2.8	Clasificación por año de publicación de los 72 artículos estudiados.	32
2.9	Artículos científicos estudiados para caracterizar el estado del arte de este trabajo.	34
2.10	Temáticas tratadas en los artículos estudiados.	35
2.11	Desglose más concreto de los problemas tratados en los artículos estudiados.	36
2.12	Categoría global de las técnicas de inteligencia artificial empleadas en los artículos estudiados.	39
2.13	Algoritmos concretos de inteligencia artificial empleados en los artículos estudiados.	40
2.14	Número de grupos de interés involucrados en cada uno de los artículos estudiados.	44
2.15	Desglose de cada grupo de interés que interviene en los artículos estudiados.	44
4.1	Porcentaje de desplazamientos desde Madrid a otras provincias.	56
4.2	Porcentaje de desplazamientos desde Barcelona a otras provincias.	57
4.3	Porcentaje de desplazamientos desde Jaén a otras provincias.	58
4.4	Porcentaje de desplazamientos desde Cuenca a otras provincias.	59

4.5	Porcentaje de desplazamientos desde Toledo a otras provincias.	60
4.6	Porcentaje de desplazamientos desde Valencia a otras provincias.	61
4.7	Ejemplo de los indicadores planteados para el coche en 5 trayectos.	64
4.8	Ejemplo de los indicadores planteados para el tren en 5 trayectos.	64
4.9	Ejemplo de los indicadores planteados para el avión en 5 trayectos.	64
4.10	Análisis comparativo de tiempos y costes entre distintos medios de transporte del 80 % de los desplazamientos producidos con origen en Madrid.	66
4.11	Análisis comparativo de tiempos y costes entre distintos medios de transporte del 80 % de los desplazamientos producidos con origen en Barcelona.	67
4.12	Análisis comparativo de tiempos y costes entre distintos medios de transporte del 80 % de los desplazamientos producidos con origen en Jaén.	67
4.13	Análisis comparativo de tiempos y costes entre distintos medios de transporte del 80 % de los desplazamientos producidos con origen en Cuenca.	68
4.14	Análisis comparativo de tiempos y costes entre distintos medios de transporte del 80 % de los desplazamientos producidos con origen en Valencia.	68
4.15	Análisis comparativo de tiempos y costes entre distintos medios de transporte del 80 % de los desplazamientos producidos con origen en Toledo.	69
4.16	Rendimiento de los tres modelos de redes neuronales propuestos para el modelo predictivo de la ruta Madrid – Barcelona.	78
4.17	Rendimiento del modelo óptimo para las rutas propuestas en los dos sentidos.	79
4.18	Rendimiento de los dos modelos óptimos entrenados con todos los datos de las 4 rutas previstas.	80
4.19	Influencia de las variables para la predicción del sensor S1.	96
4.20	Arquitectura de la red neuronal recurrente <i>LSTM</i>	98
4.21	. Resultados de entrenamiento de la <i>RNN</i>	99
4.22	Criterio de seguridad propuesto.	101
4.23	Comparación entre los valores RMSE y MAE obtenidos en diferentes casos probados.	102
4.24	Resultados de la evaluación de las redes neuronales para cada eje sobre el conjunto de prueba.	116
4.25	Resultados de la evaluación del modelo del conjunto de datos correspondientes al caso específico de la queja del viajero.	118
4.26	Estructura del modelo 1.	126
4.27	Estructura del modelo 2.	126
4.28	Estructura del modelo 3.	126
4.29	Resultados (MAE medido en m/s^2) de los 3 modelos definidos considerando las diferentes ventanas de tiempo.	127
4.30	Indicadores clave de desempeño de los modelos definidos.	128
4.31	Comparativa entre el rendimiento de una red neuronal artificial y el modelo 1.	130
4.32	Resultados optimizados del modelo 1 del caso real de degradación del confort.	130
5.1	Conclusiones principales sobre el transporte de viajeros y mercancías tanto a nivel nacional como a nivel internacional.	140
5.2	Mejores modelos hallados en cada caso de estudio.	144

Abreviaturas y acrónimos

UPM	Universidad Politécnica de Madrid
ODS	Objetivos de Desarrollo Sostenible
IA	Inteligencia Artificial
AI	Artificial Intelligence
RNN	Recurrent Neural Network
LSTM	Long Short – Term Memory
IT	Information Technology
ANN	Artificial Neural Networks
MAE	Mean Absolute Error
MAPE	Mean Absolute Percentage Error
ONU	Organización de las Naciones Unidas
SDG	Sustainable Development Goals
IEA	International Energy Agency
MITMA	Ministerio de Transportes, Movilidad y Agenda Urbana
MIT	Massachusetts Institute of Technology
RAMS	Reliability, Availability, Maintainability and Safety
EN	European Norms
UNE	Una Norma Española
IRIS	International Railway Industry Standard
WoS	Web of Science
FECYT	Fundación Española para la Ciencia y la Tecnología
INE	Instituto Nacional de Estadística
KPI	Key Performance Indicator
CBM	Condition-Based Maintenance

LTV Limitación temporal de velocidad

UE Unión Europea

CapEx Capital Expenditures

OpEx Operating Expenses

Capítulo 1

Introducción

Nos encontramos en una realidad cambiante cada día y llena de retos desde diversos puntos de vista, influenciada además por situaciones no predecibles como una pandemia o guerras con importantes consecuencias en la sociedad del siglo XXI (Siregar y Zulkarnain, [2022](#)).

La tecnología está creciendo más rápido que la capacidad de asimilación por parte de la sociedad y de las empresas. Existe, por tanto, un amplio campo de investigación y desarrollo de aplicaciones prácticas de estas tecnologías emergentes en las empresas y en la sociedad.

Las empresas actuales deben plantear un cambio de estrategia a medio y largo plazo, contratando gente especializada en el estudio y aplicación de nuevas tecnologías, más que centrarse en perfiles concretos expertos en una tecnología determinada (Blueprint Labs, [2023](#)). En los próximos años, la mayor parte de las empresas sufrirán un proceso de transformación digital que les proporcionará ventajas competenciales y una optimización general del trabajo diario.

La sociedad también se ve influenciada por este paradigma. La conciliación familiar y la flexibilidad se ven potenciadas por la aparición del teletrabajo y las profesiones que permiten asimilar la distancia geográfica. Además, la movilidad se ve claramente influenciada por este motivo, y por tanto, se consolidarán en los próximos años un nuevo concepto de empresa y nuevas profesiones (Stoian et al., [2022](#)).

Por otro lado, las nuevas tecnologías deben analizarse también desde un punto de vista más personal y desde los valores, dado que existe una preocupación creciente por la automatización de procesos que puedan eliminar profesiones existentes. Por otro lado, se está consiguiendo personificar las máquinas dado que ya son capaces de imitar comportamientos humanos y habilidades no antes vistas en ordenadores. Este aspecto, sin duda, generará un amplio debate ético en los próximos años (Munoko et al., [2020](#)). La sociedad se ve sometida a un gran reto de asimilar las nuevas tecnologías emergentes, ya que influenciará en su vida cotidiana y en la propia escala de valores personales.

Hace años, existía una preocupación por la sustitución de ciertas profesiones rutinarias por máquinas. Pero en la mayor parte de las profesiones el contacto humano es esencial por lo que no ha derivado en un gran problema social, sino más bien en una mejora de la calidad de vida y una reorientación de ciertos perfiles profesionales o puestos de trabajo. Sin embargo,

la inteligencia artificial pone de manifiesto que las máquinas pueden ser capaces de poder comportarse como de si un humano se tratara, lo cual amplía el rango de profesiones que pueden verse afectadas.

Desde un punto de vista económico, es evidente que las nuevas tecnologías están provocando un cambio importante. Por un lado, ayudan a la optimización de recursos y mejora de procesos mediante la aplicación de la inteligencia artificial. Por otro lado, el cambio de paradigma de las empresas por la implementación de las nuevas tecnologías, darán lugar también a un crecimiento económico de los países más desarrollados.

Es necesario destacar que lo anterior tendrá una influencia positiva en la investigación y desarrollo de los distintos países, siendo primordial la búsqueda de aplicaciones prácticas para las empresas.

Por último, como consecuencia directa de lo anterior, el medio ambiente se ve también influenciado. Las nuevas tecnologías y el crecimiento económico deben ir asociados a la idea de mantener, preservar y mejorar el entorno que nos rodea, conduciendo a los distintos países hacia un modelo de sostenibilidad que permita optimizar los recursos energéticos, reducir las emisiones e introducir en la ecuación del crecimiento tecnológico y económico la variable medioambiental. Hasta hace pocos años, la preocupación por el medio ambiente se reducía a aspectos de imagen y de política, o a grupos de interés minoritarios.

Afortunadamente, cada vez existen más políticas reales y con objetivos claros y medibles orientados a garantizar la sostenibilidad del mundo que nos rodea. Con este propósito nacieron los Objetivos de Desarrollo Sostenible (ODS), cuya relevancia va aumentando con el paso de los años y está presente en la mayor parte de las políticas gubernamentales de los distintos países.

1.1 Evolución de la tecnología

En el ámbito tecnológico, es evidente el crecimiento exponencial de las nuevas tecnologías como la evolución de la inteligencia artificial, la capacidad creciente de los procesadores, la aparición del blockchain o de la computación cuántica, las criptomonedas, la impresión 3D, ... Prácticamente todas las tecnologías más punteras que se están manejando en la actualidad tienen que ver con el uso y tratamiento de información, por lo que la inteligencia artificial podríamos decir que lidera la punta de lanza del progreso científico y tecnológico (Cerdán, 2022).

1. **Inteligencia Artificial generativa:** se pone de manifiesto la capacidad de emplear esta tecnología para imitar habilidades humanas como la creación de una canción, un dibujo, concatenar un razonamiento o escribir una obra literaria. Numerosos estudios se están realizando para investigar su aplicación directa en la industria o en la educación (Cooper, 2023).
2. **Realidad virtual y realidad aumentada:** ayuda a entender entornos de difícil acceso con una reproducción fiel, no solo en términos visuales sino también sensoriales (percepción del tacto, de fuerzas, ...). También se está trabajando en el ámbito de

conectar el cerebro con la computadora, para entender, interpretar y ejecutar acciones a partir de la actividad cerebral (Sutherland et al., 2018).

3. **Conectividad 5G:** pretende reducir la latencia y poder acercarnos al concepto de instantaneidad, esto es, poder trabajar fielmente en tiempo real. Esto permitirá poder crear infraestructuras interconectadas programables en tiempo real o bajo demanda con una mínima supervisión (Arrubla-Hoyos et al., 2022).
4. **Servicios en la nube:** migración generalizada de las aplicaciones, almacenamiento de información e infraestructuras a la nube, con su pertinente protección y evolución de los sistemas de ciberseguridad para proteger adecuadamente la confidencialidad de la información de los usuarios (Alonso et al., 2023).
5. **Blockchain y protección y verificación de datos:** actualmente existe una gran preocupación por la fiabilidad de la información que encontramos en las redes, dado que no es trivial comprobar la veracidad de esta. Las tres características más relevantes de la información se resumen en confidencialidad, integridad y accesibilidad. Hay una gran desconfianza en el cumplimiento de estas tres características, dado que cada vez se encuentra más información en redes que es falsa o que no está contrastada. Tecnologías como el blockchain lograrán pronto revertir la situación y garantizar a los usuarios, sean empresas o privados, el máximo nivel de seguridad, protección de la información y fiabilidad y veracidad de la misma (Pourrahmani et al., 2023).
6. **Logística autónoma:** el estudio de la información y la interconectividad a través del concepto de IoT (internet of things), logrará generar una cadena totalmente autónoma de los procesos logísticos en diferentes industrias, reduciendo al máximo la supervisión humana, los puntos de espera o presencia intermedios y automatizando pedidos, órdenes rutinarias y paradas por mantenimiento correctivo, que se orientarán mayormente en un programa de mantenimiento predictivo (Tubis y Rohman, 2023).
7. **Computación cuántica:** basado en la teoría cuántica de partículas, se está trabajando en la aplicación de esta tecnología para el tratamiento y procesamiento de información, logrando que los ordenadores puedan hacer operaciones mucho más rápido de lo que lo hacen actualmente, llegando incluso a adentrarse en el concepto de instantaneidad. Por otro lado, este avance pone en serio peligro el cifrado, contraseñas y protección de información (Couteau et al., 2023; Younan et al., 2021).
8. **Descentralización energética:** a partir de fuentes renovables y del aprovechamiento local de captación de energía, se abre una posibilidad de aparición de más comunidades (viviendas, barrios, industrias u otros colectivos) con un porcentaje de generación de energía autosuficiente y almacenamiento local, lo cual permitirá ir evitando los grandes monopolios energéticos, concienciar a la sociedad del aprovechamiento energético y reducción de emisiones, y encaminar a la sociedad hacia la sostenibilidad y cuidado del medio ambiente (Casquijo et al., 2021).

El sector IT, que engloba diferentes especialidades relacionadas con la informática y las nuevas tecnologías, se encuentra en una situación privilegiada y están actualmente surgiendo muchas empresas de este sector, que pretenden desarrollar e implementar en las empresas modelos

y procesos que aumenten la competitividad y alcancen la máxima optimización económica y social (Taherdoost, [2022](#)). Aparecen nuevos perfiles, nuevos modelos de negocio y nuevas tendencias que deben atenderse apropiadamente para garantizar el máximo nivel competencial de las organizaciones actuales.

1.2 Sostenibilidad y Agenda 2030

Desde hace décadas, existe un número creciente de grupos de interés que defienden el medio ambiente y la racionalización de recursos naturales y energéticos, con objeto de garantizar un futuro desarrollo sostenible del planeta y de la sociedad.

En los inicios, los grupos de interés eran minoritarios, y tanto las empresas, como las instituciones y los gobiernos, se escudaban en este concepto con un enfoque puramente interesado por proyectar una buena imagen a la sociedad. Con el paso de los años, y con la creciente tasa de emisiones y consumo de recursos energéticos, el concepto de sostenibilidad y preocupación por el medio ambiente ha ido pasando a un primer plano, donde se ha entendido la verdadera implicación de no revertir la situación actual y las graves consecuencias que puede conllevar (Verma et al., [2021](#)). El cambio climático es otro de los temas más relevantes que se han debatido ampliamente en diversos foros, y que también tiene relación directa con la preocupación medioambiental (Change, [2023](#)).

Por este motivo, nacen políticas internacionales, planes de acción y objetivos claros que sean medibles en los países con objeto de reconducir la situación actual.

No hace muchos años la sostenibilidad parecía ser una moda para dar buena imagen, y desde hace una década empiezan a surgir políticas gubernamentales y objetivos medibles y tangibles, que ponen de manifiesto el interés y el verdadero compromiso de trabajar seriamente en los distintos países por reducir las emisiones y garantizar un desarrollo sostenible. Nacen así, entre otras propuestas, los Objetivos de Desarrollo Sostenible (ODS o SDG en inglés) que se fijaron en el marco de la Agenda 2030.

Se trata de una cumbre celebrada en el año 2015 en la que más de 150 países que conforman la Asamblea General de la ONU, se reunieron y manifestaron su compromiso por el desarrollo sostenible del planeta. La Agenda 2030 incluye 17 objetivos aplicables universalmente, que se ponen en marcha desde el 1 de enero de 2016 con objeto de garantizar hacia el año 2030 un mundo sostenible (Hák et al., [2016](#)).



Figura 1.1: Objetivos de Desarrollo Sostenible.

En la Agenda 2030 se plantean 17 Objetivos de Desarrollo Sostenible y 169 metas o líneas de trabajo relacionadas con el ámbito social, económico y medioambiental. Se pretende con ello favorecer el cuidado del planeta, de las personas y fomentar la prosperidad, la paz universal y la justicia. Existen objetivos concretos como la erradicación de la pobreza o garantizar una educación de calidad, la igualdad de género, asegurar el acceso al agua y a la energía, fomentar el crecimiento económico sostenido, lograr la seguridad alimentaria o la adopción de medidas urgentes contra el cambio climático.

Cada país debe determinar sus políticas y planes de acción para la consecución de los objetivos y metas propuestas durante esta cumbre. El cumplimiento no es de carácter obligatorio y a finales de la presente década se analizará el grado de cumplimiento de los ODS de acuerdo a lo establecido en el año 2015 (Desarrollo Sostenible, 2017).

Existen diversas líneas de trabajo para la consecución de los objetivos anteriores. Profesionales de todos los sectores tienen un gran reto por delante y numerosos planes de acción que poner en marcha. En lo relativo a las emisiones y la sostenibilidad, de todas las áreas que tienen impacto sobre ambos conceptos, una de la más destacadas es la del transporte, que es en la que nos centraremos en este estudio.

1.3 Evolución del concepto de movilidad

A lo largo de la Historia, el concepto de movilidad ha ido evolucionando en función de las necesidades del ser humano en cada momento, y de los requisitos demandados en el transporte, tanto de personas como de mercancías. En este apartado, se analizan las distintas concepciones de la movilidad en el pasado, presente y futuro.

1.3.1 Movilidad del pasado

Hasta el siglo pasado, se ha entendido el transporte como el desplazamiento de una persona o una mercancía desde un punto inicial denominado origen, hasta un punto final denominado destino (Pappalardo et al., 2023). Siempre se ha trabajado en disminuir las distancias y los tiempos de transporte entre ciudades o poblaciones, tanto con vehículos particulares como en servicios públicos de transporte (autobús, tren, avión), manteniendo los costes asociados al viajero o usuario final en unos límites razonables. Mejorar el transporte en el pasado significaba aplicar alguna de las siguientes medidas: (Niu et al., 2023; Grande, 2023)

1. Mejorar las líneas o carreteras existentes (mejora de infraestructura).
2. Abrir nuevos trayectos ya sea por carretera, por ferrocarril o por avión.
3. Aumentar la frecuencia de los servicios públicos.
4. Disminuir los tiempos de viaje en transporte público.
5. Disminuir el precio del billete en el transporte público.
6. Mejora de las prestaciones de los vehículos privados o públicos.

De forma resumida, o bien se mejoraba el servicio prestado, o bien se disminuían los costes asociados para el usuario final. Pero no se estaba analizando el problema desde una perspectiva global, dado que no se hablaba de eficiencia energética, tasa de accidentalidad, consumo energético, sostenibilidad, adaptación de oferta y demanda o combinación de servicios de transporte.

Todo ello conlleva a que se deban tener en cuenta hoy en día otros factores que influyen en el transporte de personas o mercancías, y que tienen un impacto relevante en la sociedad y en el medio ambiente, tal y como se describe en el siguiente apartado (Nickdoost et al., 2023).

1.3.2 Movilidad del presente

El transporte tanto de personas como de mercancías es una actividad imprescindible en la sociedad de un mundo globalizado como en el que vivimos (Echelmeyer et al., 2022). Referente a las mercancías, hoy en día cualquier producto es comercializado en un alto porcentaje de los países del mundo, y por tanto existen numerosos transportes asociados a la actividad comercial. Además, las relaciones políticas y económicas entre países también necesitan del gran aumento de las importaciones y exportaciones de productos.

Se tiende a poder elegir entre todas las opciones posibles, y por tanto existe una oferta y demanda de productos muy superior a la necesaria o a la que podría considerarse imprescin-

dible, ya que solamente se tiene en cuenta el beneficio económico, y tanto el social como el medioambiental pasan a formar parte de un segundo plano (Nkesah, [2023](#)).

Con respecto a las personas, a nivel profesional, a pesar de disponer de tecnología avanzada para poder realizar videoconferencias por plataformas online, siguen siendo necesarios numerosos desplazamientos para reuniones, congresos o distintas actividades profesionales. Es cierto que, tras la pandemia, ha aumentado exponencialmente el concepto de teletrabajo, permitiendo a las personas poder vivir en su ciudad o pueblo de origen y accediendo a la vez a las mismas oportunidades laborales.

Las grandes empresas ya no tienen por qué estar enteramente concentradas en las ciudades principales, y además puede permitir la descentralización de las oficinas de una empresa. Existen muchos puestos de trabajo que permiten un 100 % de teletrabajo, y otros que tienen un porcentaje relativamente alto, lo cual impacta directamente en una disminución en parte de los desplazamientos por razones laborales, y contribuye a ofrecer una mayor flexibilidad para los trabajadores Sepanta y O'Brien, [2023](#).

Por otro lado, a nivel personal, los desplazamientos han aumentado también debido a los viajes familiares o con amigos, ya sea por motivos de ocio, por vacaciones, o por visitas temporales (Lee et al., [2023](#)). Cada vez hay más opciones, oportunidades y destinos turísticos a los que acudir.

Como se ha mencionado antes, a pesar de que los desplazamientos se vieron reducidos durante la época de la pandemia, tras la superación de ésta se vuelven a alcanzar valores similares e incluso superiores a los desplazamientos medios existentes antes de dicha crisis mundial. Estos datos pueden comprobarse, por ejemplo, en España, a partir de la fuente de datos proporcionada por el Ministerio de Transportes, Movilidad y Agenda Urbana (“Open Data Movilidad | Ministerio de Transportes, Movilidad y Agenda Urbana”, [s.f.-a](#)).

Desde que se establecieron los objetivos de la Agenda 2030, acompañado por el progreso tecnológico que vivimos, se ha evolucionado desde el concepto de transporte (movilidad del pasado) a un área mucho más global denominada movilidad (Lorig et al., [2023](#)).

El concepto de movilidad, no solo tiene en cuenta el propio desplazamiento, sino que engloba también todo lo que influye y rodea a dicho desplazamiento, entendido como un servicio general en el que participan muchas áreas distintas (Kimura y Moser, [2023](#)). Dentro de la movilidad, además del transporte o desplazamiento, se tienen en cuenta otros factores como el consumo de energía, el impacto medioambiental, la optimización de los desplazamientos en términos económicos y materiales, disponibilidad y fiabilidad de los servicios de transporte, frecuencias, accesibilidad, contribución con la sostenibilidad, etc.

En el ámbito de las mercancías, alineado con los objetivos de desarrollo sostenible, se pretende aumentar el transporte por ferrocarril, disminuyendo el transporte por carretera debido al alto impacto medioambiental que supone. En los distintos países de la Unión Europea, se viene trabajando en esta línea con objeto de contribuir con la descarbonización del transporte. Además de descargar las carreteras de mercancías, es importante disminuir el transporte aéreo de éstas, empleándose únicamente para envíos excepcionales o urgentes en los que el plazo de entrega sea fundamental.

Una vez que se haya equilibrado el trasvase de mercancías al ferrocarril, se deberán emplear las nuevas tecnologías para optimizar las rutas y la logística que le rodea. De ese modo, se logrará disminuir los recursos humanos, económicos y materiales necesarios de cara a una operación y mantenimiento eficiente y sostenible (Ng et al., 2023; Çelebi, 2023).

En cuanto al transporte de viajeros, ya se empiezan a limitar los transportes aéreos en zonas regionales o nacionales, y esta medida se está expandiendo por toda Europa. Un objetivo claro es además disminuir el uso del automóvil particular y descargar más las carreteras tanto en el ámbito urbano como en el interurbano.

Para ello, se debe continuar en paralelo potenciando el transporte público mediante el ferrocarril, alineado con las nuevas políticas de mejora de servicios, frecuencias y líneas existentes, y con la apertura de nuevas líneas convencionales o de alta velocidad que acompañen a la necesidad creciente de priorizar el ferrocarril por motivos energéticos, de sostenibilidad y de eficiencia tanto económica como energética.

A modo de ejemplo, en España se continúan potenciando nuevas líneas ferroviarias como pueda ser la Variante de Pajares recientemente inaugurada, que reducirá los tiempos de transporte entre Madrid y Asturias aproximadamente una hora. Se trata de una línea de tráfico mixto y que pretende contribuir con una mejora de los desplazamientos de personas y mercancías entre ambas ciudades (Erdei et al., 2023; Rudachenko et al., 2023).

A partir de lo anterior, se deduce claramente que Europa apuesta fuertemente por el progreso del ferrocarril, tanto para el transporte de personas como de mercancías. El motivo principal está relacionado con la eficiencia energética y la sostenibilidad, además de otras muchas ventajas importantes que presenta, como la disminución de la tasa de accidentalidad, comodidad o reducción de costes para los viajeros (Curtale et al., 2023; Litvina, 2023).

Como muestra de las ventajas del ferrocarril como medio de transporte más sostenible, se muestra a continuación una tabla con las conclusiones principales que se pueden obtener a partir de la información proporcionada por la International Energy Agency (IEA), en cuanto a consumo energético por viajero – kilómetro (“Well-to-wheel (wake/wing) GHG Intensity of Motorised Passenger Transport Modes – Charts – Data Statistics - IEA”, s.f.).

Los valores de las emisiones corresponden a un valor promedio, y se miden en CO₂e que significa dióxido de carbono equivalente. Se trata de una medida estandarizada para comparar las emisiones de los distintos gases de efecto invernadero según su potencial de calentamiento global.

Existen otras unidades para poder medir las emisiones, pero en el caso del transporte es común emplear el dióxido de carbono equivalente como medida estándar para todos. De este modo, es posible comparar distintos medios de transporte.

Medio de transporte	Factor de emisiones
Tren	19g de emisiones de CO ₂ e durante el ciclo de vida por pasajero - kilómetro
Avión	123g de emisiones de CO ₂ e durante el ciclo de vida por pasajero-kilómetro
Coche (pequeño o mediano)	148g de emisiones de CO ₂ e durante el ciclo de vida por pasajero-kilómetro

Tabla 1.1: Comparación de las emisiones medias de los distintos medios de transporte.




Figura 1.2: Comparación de las emisiones medias de los distintos medios de transporte.

A partir de los datos anteriores y de otros estudios publicados de alto impacto en el estado del arte, se determina que el tren es la solución más eficiente desde el punto de vista energético, y que debe potenciarse su uso tanto a nivel de mercancías como de viajeros.

Existe una preocupación creciente por mejorar la movilidad de los distintos países y regiones en la actualidad, prestando especial atención al transporte público como servicio para los ciudadanos.

Las mejoras que se están implementando están relacionadas con la apertura de nuevas líneas o trayectos, el aumento de la frecuencia de los servicios de transporte, fomentar el transporte multimodal de mercancías, trabajar para alcanzar un buen equilibrio entre la oferta y la demanda de transporte, y tratar de garantizar el acceso a un sistema de transporte a todos los ciudadanos y habitantes de núcleos urbanos menos poblados.

1.3.3 Movilidad del futuro

A pesar de trabajar en las mejoras mencionadas, hay todavía una serie de retos que abordar en los próximos años relacionados con la movilidad (Oliver Wyman, [s.f.](#)). Se pueden clasificar en dos categorías: resolución de problemas conocidos hoy en día, y retos futuros que derivarán de la evolución de la tecnología aplicada en el transporte.

En cuanto a los problemas existentes cabe destacar los siguientes:

1. **Optimización de la oferta y la demanda de transporte:** empleando la inteligencia artificial, se debe ir trabajando en lograr ajustar la diferencia entre la demanda de transporte por parte de los ciudadanos y la oferta que gestionan los operadores de transporte, junto con el correspondiente administrador de la infraestructura. Actualmente, se hacen estudios parciales de frecuencias y oferta de servicios, pero aplicando las nuevas

tecnologías se debería poder ajustar de manera más precisa la oferta y la demanda de los servicios de transporte. Además, esto permitiría poder tener valores monitorizados y actualizados en tiempo real, de tal manera que pueda existir tiempo suficiente para ir planificando en el corto plazo los servicios comerciales ofertados a los usuarios. Se trataría de poder predecir con modelos de alta precisión los desplazamientos de las personas y las mercancías, con tiempo suficiente para poder ir adaptando dicha oferta a la demanda de los usuarios (Hoppe et al., 2023).

2. **Optimización de recursos económicos y humanos destinados a los servicios de transporte:** aplicando las nuevas tecnologías, se conseguirá reducir la cantidad de personas y recursos materiales destinados a la operación y el mantenimiento de los distintos sistemas de transporte (J. Zhang y Zhang, 2023).
3. **Nuevo planteamiento de la red de transporte:** debido a la potenciación del uso del ferrocarril para el transporte de mercancías y de viajeros, se deberán replantear las rutas existentes, programar nuevos trayectos, ajustar las relaciones en el transporte multimodal con los otros medios de transporte involucrados y adaptar la operación al nuevo escenario. Se trata de replantear la estrategia a seguir durante los próximos años. Esta estrategia debe aplicarse tanto a nivel local como a nivel nacional, asegurando la integración óptima entre ambos modelos.
4. **Implementación de la industria 4.0 en el sector del transporte:** es necesario dar el salto a nivel global a la industria 4.0, incorporando los datos y su análisis mediante inteligencia artificial como herramienta fundamental para la toma de decisiones, y para la optimización de la operación y del mantenimiento de los distintos medios de transporte (Bugaj et al., 2023; Židová y Zitrický, 2023).
5. **Garantizar la accesibilidad a todos los ciudadanos:** a día de hoy siguen existiendo diferencias notables entre regiones, e incluso numerosas poblaciones que no tienen acceso a un sistema público de transporte regular.
6. **Regiones despobladas:** en España, durante los últimos años, se ha observado una gran movilización de la población a las grandes ciudades, abandonando regiones y pueblos de pocos habitantes. Esto causa una sobreocupación y crecimiento incontrolado de las grandes ciudades, y por otro lado causa una despoblación conocida en nuestro país como la “España vaciada”. Uno de los motivos principales se debe a las malas o inexistentes conexiones de muchas regiones con las grandes ciudades. A nivel político, es un tema importante a abordar en el futuro cercano (Valenzuela y Holl, 2023).
7. **Equilibrio de costes y tiempos:** todos los ciudadanos deberían poder acceder a un sistema de transporte equilibrado en cuanto a tiempos y costes, dentro de una horquilla razonable en función del trayecto y del medio de transporte empleado.

Los puntos anteriores se corresponden con problemáticas ya conocidas pendientes de resolver durante los próximos años. Sin embargo, la evolución de las nuevas tecnologías podrá afectar de forma directa en la organización del transporte futuro. Por ello, además de revisar los puntos anteriores, es altamente probable que la sociedad deba enfrentarse además a los siguientes retos:

1. **Creación de una nueva red de transporte por implantación o cambio de la tecnología base:** se puede deber a la evolución de los vehículos eléctricos o a la aparición de la tecnología de hidrógeno u otra tecnología alternativa. Actualmente, ni a nivel de operación ni de infraestructura está preparada la red para poder absorber de forma íntegra una flota completa de vehículos eléctricos o de tracción por hidrógeno (Tao et al., 2023; Saeed et al., 2023).
2. **Posibilidad de compartición de vehículos:** con objeto de contribuir con el ahorro energético, se continúa investigando en el modelo de compartición de vehículos, hasta tal punto que se baraja la opción de no existir la propiedad privada de vehículos a futuro, sino una flota a la que se tiene acceso cuando se necesite. Este modelo de gestión de flotas ya existe en el sector público (por ejemplo con los autobuses), y han aparecido diversas compañías privadas de alquiler de vehículos que también se basan en este concepto como Car2go o Wible (Alpos et al., 2022; Briguglio y Formosa, 2023).
3. **Posibilidad de compartición de energía eléctrica:** a día de hoy, los vehículos son capaces de cargar la batería en puntos concretos mientras están parados, ya sea en puntos de carga repartidos en la ciudad o bien en sus domicilios particulares. Sin embargo, si continúa creciendo el mercado de los coches eléctricos, conviene pensar la posibilidad de poder cargar la batería en marcha, o incluso poder cargar un vehículo con otro vehículo que esté en circulación en concepto de compartición de energía entre la flota de vehículos. Desde hace unos años, instituciones como el MIT Media Lab vienen investigando estas ideas (González et al., 2021).

El futuro del transporte todavía es muy incierto, aunque el nuevo concepto de movilidad futura ha venido para quedarse. Actualmente, los grupos de investigación y las empresas industriales deben seguir trabajando en la evolución de nuevas posibles tecnologías que logren optimizar los vehículos, su operación, la infraestructura, la logística y el mantenimiento, de cara a determinar prontamente qué camino se determinará en los próximos años. Esto permitirá adecuar la infraestructura, y organizar de manera óptima la red de transportes (Gharehbaghi et al., 2023).

Por otro lado, las instituciones públicas hoy en día deben concentrarse en tratar de optimizar la red existente, y acercar la oferta y la demanda a las necesidades reales de las personas y las mercancías, sacando el mayor provecho posible de los medios de transporte más sostenibles con el medio ambiente como es el caso del ferrocarril.

Para lograr la máxima optimización mencionada es necesario hacer uso de las nuevas tecnologías, y más concretamente, de la inteligencia artificial. Existen ingentes cantidades de datos que generamos a diario pero que no somos capaces de sacarle provecho suficiente (Beeckmans et al., 2023).

En el caso particular del transporte, conviene estudiar los datos para conocer la movilidad de las personas y mercancías comparándolo con sus necesidades reales, siendo mucho más fácil poder adaptar la oferta y la demanda. Además, el análisis de los datos mediante la inteligencia artificial, ayudará a optimizar la operación y mantenimiento tanto de la infraestructura como de los vehículos, alcanzando mayores tasas de disponibilidad y fiabilidad con el menor número posible de recursos invertidos. Todo ello desembocará en una metodología capaz de instaurar

un modelo optimizado de movilidad inteligente.

Este trabajo se centrará en la aplicación de la mencionada metodología en el sector ferroviario, siendo posible extrapolarlo a los demás medios de transporte, e incluso recomendable poder analizar a futuro la foto más completa con todos los medios de transporte existentes.

Este análisis particularizado en el ferrocarril, debe hacerse desde un punto de vista global. Es común estudiar un problema de manera aislada sin pensar en las implicaciones globales en su conjunto. En el ámbito de la movilidad ferroviaria, intervienen principalmente tres actores diferenciados: el operador, el administrador de la infraestructura, y el fabricante y mantenedor de los vehículos ferroviarios. Dado que nunca una sola compañía ha abordado los tres roles, es muy difícil trabajar en un problema desde un punto de vista general, y cada uno trata de optimizar su parcela sin tener en cuenta los otros dos participantes.

Esto ha ocurrido de forma sistemática, con el agravante de que a día de hoy recogemos muchos datos e información de los trenes o de la infraestructura y operación, y seguimos sin estar abiertos a compartirlos entre todos para generar valor añadido al transporte ferroviario. Poco a poco deberá cambiarse esta tendencia, para poder trabajar en soluciones potencialmente beneficiosas para el sector en general. Los datos deben compartirse con el buen propósito de encontrar la mejora continua y la optimización global que beneficie a todas las partes.

Este trabajo pretende proponer una metodología que, empleando la inteligencia artificial, logre optimizar los recursos humanos y materiales empleados en la movilidad ferroviaria, teniendo siempre en cuenta los tres puntos de vista, esto es, al operador, al de la infraestructura y al mantenedor del vehículo ferroviario. Esta idea forma parte del concepto de movilidad inteligente, que es al que se debe tender durante las próximas décadas, con objeto además de conseguir los objetivos ya implantados para el año 2050 en materia de sostenibilidad, transporte y movilidad (J. Chen et al., [2023](#)).

Capítulo 2

Estado del arte

En este capítulo se pretende realizar un estudio detallado sobre la movilidad de mercancías y viajeros en Europa durante los últimos años, analizando además las principales características demandadas a los servicios de transporte.

Conocida esta información, en una segunda sección, se pretende elaborar una revisión sistemática de la literatura existente acerca de la aplicación de la inteligencia artificial en el sector ferroviario.

De esta manera, se podrá conocer la situación actual de la implementación de modelos de inteligencia artificial en la movilidad ferroviaria. Asimismo, se entenderán los principales retos que no han sido resueltos todavía o que no se han investigado. Esto permitirá justificar la necesidad real de una metodología de implantación de movilidad inteligente, que es el objetivo principal de esta tesis.

2.1 Antecedentes de la movilidad en Europa

En un primer subapartado, se va a analizar la movilidad durante los últimos años tanto de mercancías como de viajeros, para entender el punto de partida de cara al planteamiento de una metodología para la movilidad futura. Este estudio se ha realizado a partir del observatorio de transporte y logística de España, y contiene una comparación del transporte de mercancías y viajeros tanto a nivel nacional como a nivel internacional. Se diferencia asimismo por cada medio de transporte en particular, obteniendo de este modo una visión más completa de la movilidad en los últimos años.

En un segundo subapartado, se exponen de manera resumida los principales requisitos demandados a los servicios de transporte. Estos requisitos pueden venir impuestos desde la operación o desde el mantenimiento. Esta reflexión ayudará a entender qué características deben seguir trabajándose, con objeto de ser optimizadas al máximo empleando las nuevas tecnologías, y de aplicación para cualquier medio de transporte.

A partir de lo anterior, se conocerá cómo se han movido hasta ahora los viajeros y las mercancías, y qué se espera de un servicio de transporte como usuario final. Esta información

es relevante para posteriormente poder fusionar estas dos ideas expuestas en una sola, derivando hacia un concepto de movilidad y dejando atrás el concepto tradicional de transporte.

2.1.1 Evolución del transporte de viajeros y mercancías

En este apartado se analiza el progreso en los últimos años de los desplazamientos de viajeros y mercancías tanto en España como a nivel internacional, a partir de los datos obtenidos del OTLE (Observatorio del Transporte y la Logística en España, “Portal del Observatorio del Transporte y la Logística en España, OTLE”, [s.f.](#)).

Todas las figuras que aparecen en esta sección muestran un índice cuyo valor es 100 en el año 2007, de tal modo que se pueda comparar los datos del resto de los años con los valores alcanzados durante este año 2007.

El transporte de viajeros a nivel nacional se mide en millones de viajeros – kilómetro. El transporte de viajeros a nivel internacional se recoge en millones de kilómetros. Y el transporte de mercancías se mide en miles de toneladas. De este modo, si por ejemplo se obtiene un valor de 87,3 en el transporte de viajeros por carretera en ámbito nacional en el año 2021, significa que el número de viajeros – kilómetro ha disminuido un 12,7 % con respecto al año 2007 (que es al que se otorga por convenio el valor de 100).

Desde aproximadamente el año 2014 hasta la llegada de la pandemia, la tendencia de la evolución total del transporte de viajeros y mercancías a nivel internacional era creciente, salvo el transporte de viajeros a nivel nacional que parece mantenerse estable. Sin embargo, desde el 2007 hasta el 2014, al contrario de lo que sucedía en Europa, en España disminuye la cantidad de desplazamientos y transporte de mercancías. Todo esto puede observarse en la figura 2.1.



Figura 2.1: Evolución total del transporte de viajeros y mercancías tanto en España como a nivel internacional.

En España, el crecimiento tanto de mercancías como de viajeros no ha sido tan acusado en este periodo, si bien es cierto que las directrices europeas en cuanto a políticas de movilidad y transporte, tardan un tiempo en generar impacto en nuestro país. Un posible motivo es el efecto retardado en la implantación en España de dichas políticas. Esto explicaría el desfase entre la evolución internacional y la evolución en este país.

Se mostrarán a continuación los siguientes gráficos de forma separada: evolución del transporte de viajeros a nivel nacional, evolución del transporte de viajeros a nivel internacional, evolución del transporte de mercancías a nivel nacional, y evolución del transporte de mercancías a nivel internacional.

En cuanto a la evolución total del transporte de viajeros, medido en viajeros – kilómetro, puede observarse que el crecimiento es mayor a nivel internacional, sobre todo durante los últimos años. No sucede lo mismo a nivel nacional, dado que desde el año 2007 hasta el año 2014 incluso disminuyeron los desplazamientos de viajeros. Posteriormente la tendencia comienza a ser creciente. Esto puede observarse en las figuras 2.2 y 2.3.



Figura 2.2: Evolución del transporte de viajeros a nivel nacional.



Figura 2.3: Evolución del transporte de viajeros a nivel internacional.

Analizando la evolución del transporte de mercancías, tal y como puede comprobarse en la figura 2.4 y en la figura 2.5, la situación es similar a la expuesta con los viajeros. Se denota una clara tendencia creciente a nivel internacional desde el año 2009, y sin embargo en España cayó de forma acusada hasta el año 2013, a partir del cual se recupera una tendencia creciente, pero con una pendiente menor a la existente en la situación internacional.



Figura 2.4: Evolución del transporte de mercancías a nivel nacional.



Figura 2.5: Evolución del transporte de mercancías a nivel internacional.

Como conclusión, la evolución del transporte de viajeros y mercancías en España no es excesivamente fiel a la situación que se refleja en Europa. Por otro lado, es cierto que la tendencia es creciente en ambos ámbitos, esto es, que el número de desplazamientos y mercancía transportada es creciente en los últimos años, exceptuando el periodo de pandemia.

Tras la pandemia, se vuelve a proyectar una tendencia ascendente de los desplazamientos y transportes de mercancías, por lo que es de especial interés seguir investigando en este campo, para que el crecimiento esté alineado de forma óptima con las políticas europeas de sostenibilidad y eficiencia energética. Otro objetivo debe ser aprovechar las ventajas evidentes de la aplicación de las nuevas tecnologías, expuestas en el primer apartado de este documento.

Dado que existen distintos modos de transporte, es interesante analizar la contribución y situación de cada uno de ellos en las conclusiones anteriormente expuestas. Por tanto, se van a estudiar los cuatro modos de transporte existentes: transporte ferroviario, transporte por carretera, transporte aéreo y transporte marítimo. Se va a diferenciar asimismo el ámbito nacional e internacional, y los transportes de mercancías y viajeros. Este análisis permitirá finalmente extraer conclusiones más detalladas sobre la situación del ferrocarril, en comparación con los otros modos de transporte.

En las figuras 2.6, 2.7, 2.8 y 2.9, se observa la evolución del transporte de viajeros a nivel nacional en cada uno de los modos de transporte mencionados. En los cuatro la evolución es similar a la presentada en la gráfica general de la figura 2.2.




Figura 2.6: Evolución del transporte ferroviario de viajeros a nivel nacional.



Figura 2.7: Evolución del transporte por carretera de viajeros a nivel nacional.

Evolución del transporte aéreo de viajeros nacional (viajeros-km). Índice 2007 = 100



Figura 2.8: Evolución del transporte aéreo de viajeros a nivel nacional.

Evolución del transporte marítimo de viajeros nacional (viajeros-km). Índice 2007 = 100



Figura 2.9: Evolución del transporte marítimo de viajeros a nivel nacional.

A partir de las figuras anteriores, cabe destacar que el ferrocarril logró mantener e incluso crecer en número de viajeros antes de la pandemia, a pesar de que la tendencia global era disminuir el número de desplazamientos de viajeros. Esto significa que el ferrocarril ya empezaba a cobrar más importancia, como medio de transporte preferido en el entorno nacional. El transporte marítimo también sufre una subida pronunciada de viajeros en los últimos años previos a la pandemia. Sin embargo, se denota una disminución de viajeros en la carretera, y a su vez una tendencia no creciente en el sector aéreo, alineado con las políticas de descarbonización del transporte.

A continuación, analizaremos la misma situación a nivel internacional, para poder comparar la evolución que ha tenido fuera de España el transporte de viajeros.

Evolución del transporte ferroviario de viajeros internacional (viajeros). Índice 2007 = 100



Figura 2.10: Evolución del transporte ferroviario de viajeros a nivel internacional.

Evolución del transporte por carretera de viajeros internacional (viajeros). Índice 2007 = 100



Figura 2.11: Evolución del transporte por carretera de viajeros a nivel internacional.



Figura 2.12: Evolución del transporte aéreo de viajeros a nivel internacional.



Figura 2.13: Evolución del transporte marítimo de viajeros a nivel internacional.

Analizando la situación internacional con las gráficas anteriores, en general se ha mantenido una evolución creciente hasta antes de la pandemia, destacando un mayor crecimiento del transporte ferroviario a partir del año 2014, lo que pone de manifiesto nuevamente la apuesta en Europa por el transporte por ferrocarril, con objeto de reducir las emisiones y garantizar una sostenibilidad en el ámbito del transporte de viajeros.

Cabe destacar que también existe un crecimiento pronunciado a partir del año 2014 en el sector aéreo, lo cual no va en contra de la política anterior, dado que es conocido que el sector ferroviario tiene una influencia en un radio limitado de kilómetros. Este radio de influencia se encuentra entre los 500 y los 800 km (Z. Chen, 2017).

En cuanto a las mercancías, se muestra a continuación la evolución desglosada por cada uno de los medios de transporte en el ámbito nacional.




Figura 2.14: Evolución del transporte ferroviario de mercancías a nivel nacional.




Figura 2.15: Evolución del transporte por carretera de mercancías a nivel nacional.



Figura 2.16: Evolución del transporte aéreo de mercancías a nivel nacional.



Figura 2.17: Evolución del transporte marítimo de mercancías a nivel nacional.

A nivel nacional, llama la atención que el transporte de mercancías por ferrocarril es oscilante, y no ha presentado en los últimos años antes de la pandemia una tendencia clara. En parte, dicha inestabilidad puede darse debido a la apertura de nuevas líneas de alta velocidad, y por tanto a la reducción de servicios comerciales por vía convencional, no tanto por la disponibilidad de surcos, sino por un problema de planificación de los servicios a medio y largo plazo. En otras palabras, no se ha cerrado de forma determinante una estrategia definitiva en cuanto al transporte de mercancías se refiere en el país.

Con respecto al transporte por carretera y avión, la evolución es similar. Hasta el 2013 la tendencia es decreciente, y a partir de ahí pasa a ser creciente hasta la llegada de la pandemia. Algo similar con un crecimiento más acusado, ocurre con el transporte marítimo.

Se muestran, a continuación, los gráficos correspondientes a la evolución del transporte de mercancías a nivel internacional para cada uno de los medios de transporte.



Figura 2.18: Evolución del transporte ferroviario de mercancías a nivel internacional.




Figura 2.19: Evolución del transporte por carretera de mercancías a nivel internacional.



Figura 2.20: Evolución del transporte aéreo de mercancías a nivel internacional.



Figura 2.21: Evolución del transporte marítimo de mercancías a nivel internacional.

A nivel internacional, sin embargo, la situación es muy distinta. Ya desde el 2009 se aprecia un incremento del transporte de mercancías por ferrocarril, avión, o barco. En cuanto al transporte internacional de mercancías por carretera, hasta el 2012 no empieza a presentar una tendencia creciente, aunque menos acusada que en el resto de los medios de transporte. Nuevamente, se hace notar la estrategia ya dictaminada por Europa de ir descarbonizando el sector, trasladando el transporte de mercancías y viajeros desde las carreteras a medios alternativos más sostenibles (Aminzadegan et al., 2022, Da Silva et al., 2023).

A modo resumen, se recoge en la tabla 2.1 un resumen de las conclusiones principales extraídas del análisis realizado en este apartado.

Periodo 2007 – 2019	Nacional	Internacional
Viajeros	Estable	Tendencia creciente alcanzando mayores valores
Mercancías	Creciente hasta 2013	Tendencia creciente alcanzando mayores valores

Tabla 2.1: Conclusiones principales sobre el transporte de viajeros y mercancías tanto a nivel nacional como a nivel internacional.

En España, el punto de inflexión de la tendencia del transporte de mercancías y viajeros se presenta años posteriores al de la media europea. Tal y como se ha mencionado anteriormente, se detecta un efecto retardado con respecto a la media de los países europeos.

Las mercancías y los viajeros transportados han aumentado en los últimos años a nivel internacional. Cruzando esta información con la situación particular del transporte por carretera, se llega a la conclusión de que se está trabajando en la línea de reducir el transporte por carretera, tanto de mercancías como de viajeros. Este concepto está recogido en una de las líneas principales de las políticas europeas relacionadas con la movilidad sostenible.

Para terminar este apartado, se recogen en las tablas 2.2 y 2.3 los datos generales de la evolución del transporte de viajeros y mercancías, tanto a nivel nacional como a nivel internacional desde el 2007 hasta antes de la pandemia en 2019 (tabla 2.2), y hasta los datos más recientes de 2021 (tabla 2.3). En las tablas 2.4 y 2.5 se pueden encontrar los datos desglosados por modo de transporte.

2007 – 2019	Nacional	Internacional
Viajeros	96,5	132,5
Mercancías	63,2	118

Tabla 2.2: Resumen de las tendencias de la evolución del transporte de viajeros tanto a nivel nacional como a nivel internacional desde el 2007 hasta la llegada de la pandemia en 2019.

2007 – 2021	Nacional	Internacional
Viajeros	85,3	Sin datos del 2021
Mercancías	66,2	116,3

Tabla 2.3: Resumen de las tendencias de la evolución del transporte de viajeros tanto a nivel nacional como a nivel internacional desde el 2007 hasta los datos más actuales del 2021.

A nivel nacional se concluye que el transporte de mercancías y viajeros ha disminuido desde el año 2007 hasta la llegada de la pandemia. Sin embargo, internacionalmente hay un aumento tanto de la cantidad de viajeros transportados, como de la cantidad de mercancía transportada. Después de la pandemia, la tendencia es nuevamente creciente si revisamos datos más actualizados que contengan 2022 y 2023, dado que en 2021 todavía no se ha normalizado la situación. En España aun así, no se han recuperado los valores que proyectamos en su día en el año 2007.

Medio	Viajeros nacional	Viajeros internacional
Ferrocarril	Creciente	Creciente desde 2014
Carretera	Creciente	Creciente desde 2016
Aéreo	Estable	Creciente desde 2014
Marítimo	Creciente desde 2012	Creciente desde 2014

Tabla 2.4: Resumen de las tendencias de la evolución del transporte de viajeros tanto a nivel nacional como a nivel internacional por modo de transporte.

Medio	Mercancías nacional	Mercancías internacional
Ferrocarril	Oscilante y estable	Decreciente hasta 2009
Carretera	Decreciente hasta el 2014	Decreciente hasta 2012
Aéreo	Decreciente	Creciente
Marítimo	Oscilante y estable	Creciente

Tabla 2.5: Resumen de las tendencias de la evolución del transporte de mercancías tanto a nivel nacional como a nivel internacional por modo de transporte.

A modo representativo, se muestran a continuación dos tablas de indicadores:

- Tabla 2.6: contiene los valores de los indicadores en el año 2019, con objeto de entender la evolución del transporte de viajeros y mercancías desde el año 2007 hasta la llegada de la pandemia.
- Tabla 2.7: contiene los valores de los indicadores en el año 2021, con objeto de entender la evolución del transporte de viajeros y mercancías desde el año 2007 hasta la actualidad (con los datos más recientes aportados por el OTLE).

Los valores anteriores muestran la variación en porcentaje relativo de los millones de viajeros – kilómetro transportados, en caso del ámbito internacional en millones de kilómetros, y miles de toneladas transportadas en comparación con el año 2007.

2007 – 2019	Viajeros		Mercancías	
	Nacional	Internacional	Nacional	Internacional
Ferrocarril	135,1	119,4	80,2	101,4
Carretera	93,9	112,9	62,1	106,8
Aéreo	101,7	158,3	57,8	227,5
Marítimo	144,2	129,2	103,9	121,2

Tabla 2.6: Resumen de los indicadores de la evolución del transporte de viajeros y mercancías tanto a nivel nacional como a nivel internacional en el año 2019 por modo de transporte.

A nivel nacional, el ferrocarril y el marítimo son los que porcentualmente más viajeros han

ganado. En cuanto a las mercancías el único que incrementa su cuota es el marítimo. En cuanto al ámbito internacional, se denota un mayor crecimiento porcentual en los viajeros del sector aéreo, siendo este incremento porcentual mucho mayor en el ámbito de las mercancías.

2007 – 2019	Viajeros		Mercancías	
	Nacional	Internacional	Nacional	Internacional
Ferrocarril	135,1	119,4	80,2	101,4
Carretera	93,9	112,9	62,1	106,8
Aéreo	101,7	158,3	57,8	227,5
Marítimo	144,2	129,2	103,9	121,2

Tabla 2.7: Resumen de los indicadores de la evolución del transporte de viajeros y mercancías tanto a nivel nacional como a nivel internacional en el año 2021 por modo de transporte.

La tabla 2.7 muestra la situación de la evolución del transporte hasta el año 2021, con objeto de entender la tendencia creciente desde la pandemia hasta nuestros días. Sin embargo, los valores de 2021 no puedan ser concluyentes, dado que el efecto de dicho evento atípico no se puede dar por terminado en ese momento. Cabe destacar que las mercancías a nivel nacional e internacional por carretera, sufren una rápida reactivación. Presentan además niveles superiores de toneladas transportadas en 2021 con respecto a 2019, dado que el transporte por mercancías es lo que antes se reactiva tras la pandemia. Lo mismo sucede a nivel internacional con el transporte ferroviario de mercancías. El resto de modos de transporte sufren un crecimiento tras la pandemia, sin conseguir todavía en 2021 los valores habituales de la situación normalizada. Por último, dado que esta tesis se centra primordialmente en el sector ferroviario, se presentan las conclusiones principales relacionadas con este modo de transporte:

- En cuanto al transporte de viajeros a nivel nacional, es el que mayor evolución presenta (después del marítimo, el cual presenta además una cuota minoritaria de viajeros). A pesar de que en general hay una disminución de los viajeros transportados desde el año 2007, en el ferrocarril se obtiene en el año 2019 un aumento de un 35,1 % de la cantidad de viajeros transportados. Uno de los motivos es el desarrollo potenciado de las líneas de alta velocidad, y la apertura de nuevas conexiones ferroviarias en el país durante los últimos años.
- Referente al transporte de mercancías a nivel nacional, el marítimo es el único que logra aumentar la cantidad de mercancía transportada en comparación con el año 2007. El ferrocarril es el que menos cuota de mercado pierde en comparación con los demás modos de transporte, presentando un 80,2 % de la cantidad de toneladas transportadas con respecto a dicho año.
- En cuanto al transporte de viajeros a nivel internacional, el transporte ferroviario queda en tercer lugar después del transporte aéreo y marítimo, con un 19,4 % de crecimiento de cuota de viajeros en comparación con el año 2007.
- En referencia al transporte de mercancías en el ámbito internacional, desde el año 2007

hasta el 2019 es el que menor crecimiento ha sufrido, dado que se mantiene prácticamente en los mismos valores.

Puede concluirse que en España se ha potenciado mucho el transporte ferroviario de viajeros, y se continúa apostando por aumentar la cuota de viajeros – kilómetro, en este modo de transporte. El crecimiento porcentual es mayor en comparación con el que ha sufrido Europa en los últimos años. En cuanto al transporte de mercancías, también es el que mayor cuota presenta a nivel nacional (después del marítimo), no siendo así a nivel internacional puesto que el ferrocarril ocupa el último lugar.

En España, la situación queda alineada con las nuevas políticas europeas de la descarbonización del transporte, y la tendencia a crear una movilidad más eficiente desde el punto de vista energético, hablando así de movilidad sostenible. A nivel de viajeros, se ha visto muy impulsado a través del plan de movilidad nacional, no quedando tan definida la estrategia de mercancías en los próximos años, en la cual se está trabajando a nivel interno, de cara a quedar la estrategia definida de forma inminente. En cuanto a la situación europea, dichas políticas deberían revertir la tendencia, y encabezar al sector ferroviario como medio preferido para el transporte de viajeros y mercancías, en las distancias apropiadas para ello.

En la figura 2.22 se aglutina la evolución del transporte ferroviario tanto de mercancías como de viajeros, a nivel nacional e internacional. Las conclusiones de esta figura ya han sido expuestas a lo largo del apartado.



Figura 2.22: Evolución del transporte ferroviario de mercancías y viajeros a nivel nacional e internacional.

2.1.2 Prestaciones demandadas a los servicios de transporte

En esta sección, se resumirán las exigencias básicas que se requieren de cualquier sistema de transporte hoy en día. Desde el punto de vista del viajero, se busca tener un sistema de transporte que presente las siguientes características:

- **Accesibilidad:** es importante garantizar a todos los usuarios la accesibilidad a la red de transporte pública. Se entiende por accesibilidad, el hecho de no tener que emplear ningún transporte privado para trasladarse desde un origen a un destino, y poder acceder al mismo caminando desde sus respectivos hogares o centros de trabajo (Kwatra et al., 2023).
- **Frecuencia y con variedad de horarios:** debe haber una frecuencia suficiente y cubrir el mayor rango horario posible, para poder adaptarse a las necesidades de las personas. Es fundamental que el transporte sea un medio y una ayuda para el viajero, y

que no deban adaptar su rutina a la oferta del transporte (Wallimann et al., 2023).

- **Seguridad:** es evidente que la seguridad debe estar garantizada íntegramente en cualquier medio de transporte público. Los viajeros no hablan frecuentemente de la seguridad, porque se considera más que superada y conseguida hoy en día (Odiijk et al., 2023, “A category classification based safety risk assessment method for railway wagon loading status”, 2023).
- **Fiabilidad:** esta es una de las características más importantes para los viajeros. Garantizar el éxito del transporte desde un origen a un destino, en el tiempo estipulado y en el horario establecido, es fundamental para demostrar la calidad de un servicio de transporte. Averías en los vehículos o en la infraestructura, penalizan gravemente la fiabilidad del servicio de transporte, lo cual influye negativamente en la satisfacción de los usuarios finales (Leutwiler y Corman, 2023, Du et al., 2023).
- **Comodidad:** los usuarios también valoran ir cómodos y en unos vehículos limpios, cuidados y con un mantenimiento del interior perceptible. Se valora positivamente poder viajar sentado y el confort de la butaca, entre otros aspectos (Silva et al., 2023).
- **Económico:** todo usuario busca optimizar los costes, y buscar la alternativa más económica posible dentro de unos tiempos razonables de trayecto. El hecho de ser económico está muy relacionado, entre otros, con la fiabilidad, la frecuencia o la accesibilidad, por lo que se debería trabajar en encontrar un equilibrio adecuado entre todas las prestaciones demandadas al servicio de transporte.
- **Servicios auxiliares:** sobre todo debido a la aparición de las nuevas tecnologías se han ido introduciendo en los medios de transporte servicios auxiliares para el viajero, que aumentan su confort y convierten el transporte en una experiencia orientada al viajero. Este concepto se conoce como experiencia de usuario, y está siendo investigado y evaluado durante los últimos años. Al igual que el concepto de transporte está evolucionando hacia el de movilidad, el concepto de viaje de las personas se está transformando en un concepto de experiencia de viaje, donde entran en juego otra serie de prestaciones y servicios que rodean al transporte. Esto da lugar a un acompañamiento al viajero para hacer el viaje más cómodo, ameno y entretenido. Algunos de estos servicios auxiliares ya han sido implantados en el pasado como la disponibilidad de enchufes en las butacas, la existencia de máquinas expendedoras o de un coche cafetería en los trenes, servicio de Información al viajero o la posibilidad de ver películas o escuchar música durante el trayecto. Sin embargo, otros empiezan a introducirse recientemente, como pueda ser la conexión WiFi, el poder conectar tu usuario de plataformas de audio o vídeo como Spotify o Netflix, o la posibilidad de personalizar el menú gastronómico o la elección de butacas, en función de las preferencias de cada usuario (Drouet et al., 2023, Maier et al., 2023, L. Wang et al., 2023).

Existen numerosos estudios que hablan de los aspectos más valorados por el usuario como por ejemplo este estudio de *CityLab Transportation*, en el que se concluye que las características más valoradas en un sistema de transporte público son la rapidez, la frecuencia y la accesibilidad (Bliss, 2016). Cabe desatacar que los servicios auxiliares cobran más importancia cuanto mayor es la duración del viaje. En trayectos urbanos o de pequeña duración, estos factores pueden

ser irrelevantes para la elección del modo de transporte, cobrando una mayor importancia la frecuencia de servicios y el tiempo de viaje.

Sin embargo, desde el punto de vista de los grupos de interés que intervienen en el servicio de transporte (operador, infraestructura, fabricante y mantenedor del vehículo), los aspectos más importantes han sido y siguen siendo los mismos, que son los englobados en el concepto RAMS (reliability, availability, maintainability and safety): fiabilidad, disponibilidad, mantenibilidad y seguridad.

- **Fiabilidad:** se entiende por fiabilidad a un concepto más global al que tienen los viajeros. No solamente se busca dar un buen servicio, sin fallos o averías que afecten al tiempo de trayecto, sino que además se busca que todos los componentes se comporten según lo esperado, basándose en el mantenimiento preventivo y sin tener que incurrir en numerosos correctivos. En otras palabras, se busca que los componentes duren lo máximo posible, o al menos lo estipulado en el LCC (life cycle cost) comprometido por el fabricante. De este modo, no se incrementarán los costes asociados al mantenimiento debido a una falta de fiabilidad de los componentes (Mo et al., 2022).
- **Disponibilidad:** se pretenden alcanzar valores cercanos al 100 % de la disponibilidad, es decir, que siguiendo el programa de mantenimiento preventivo pensado para un vehículo ferroviario, pueda garantizarse siempre la disponibilidad del mismo tras cada una de las intervenciones de mantenimiento, para poder operar comercialmente. De esta manera, es posible planificar los servicios comerciales que va a realizar cada una de las composiciones con suficiente antelación, evitando tener que emplear composiciones de reserva para sustituir al titular de dicho servicio comercial (Del Castillo et al., 2023).
- **Mantenibilidad:** se entiende por mantenibilidad, al cumplimiento fiel del plan de mantenimiento preventivo previsto para las composiciones ferroviarias. Existen numerosas intervenciones de mantenimiento preventivo, aunque en cada paso del tren por la base de mantenimiento, se chequean y se subsanan los correctivos necesarios. Estas intervenciones para llevar a cabo el mantenimiento preventivo, disponen de un tiempo determinado y de unos recursos económicos, humanos y materiales específicos. Asegurar la mantenibilidad significa ser fiel al programa previsto por el fabricante, una vez se ha entregado el tren al operador. De este modo se garantizan tiempos y costes, y se evitan riesgos en la operación comercial.
- **Seguridad:** tal y como se ha comentado anteriormente la seguridad es un concepto ampliamente estudiado e investigado en el sector. Para garantizar la seguridad, existe una monitorización constante, de todos los parámetros y variables imprescindibles para garantizar la seguridad de la operación comercial de cualquier vehículo ferroviario. Adicionalmente, existe una matriz de riesgos y una serie de mitigaciones en la operación ferroviaria, que contempla todas las casuísticas posibles que puedan interferir en la seguridad del servicio comercial (Seraco y Neto, 2023).

Una vez expuestas las características más importantes, tanto para los usuarios como los proveedores del servicio de transporte, es importante entender los retos principales a los que se enfrenta el sector durante estos años. El objetivo es poder concentrar los esfuerzos futuros en alcanzar soluciones optimizadas, en respuesta a estos retos.

A nivel de usuario, se espera conseguir una mayor adecuación de la oferta de servicios de transporte a las necesidades reales de las personas, garantizando una frecuencia adecuada para no depender en un traslado de los horarios del transporte. Además, tanto los costes como los tiempos de traslado deben mantenerse en un rango razonable, para que el transporte público siga siendo la mejor opción de viaje en la mayor parte de las situaciones. Como objetivo secundario, una mayor disponibilidad de servicios auxiliares, dará como resultado un aumento del confort del viajero y por tanto una contribución positiva con el futuro de la experiencia de usuario. La fiabilidad y la seguridad se dan por garantizadas.

Desde el punto de vista de los grupos de interés del servicio de transporte, entre los que se encuentran las instituciones y organismos públicos (generalmente el administrador de infraestructuras y el operador), es importante conseguir mejores resultados en relación con el concepto RAMS expuesto anteriormente. En cuanto a la fiabilidad de los servicios, se debe tender a alcanzar el mayor número de kilómetros posible como valor objetivo. En un tren de alta velocidad, se pretende tener un objetivo retador en el entorno de los dos millones de kilómetros.

A nivel de disponibilidad, se persiguen valores muy cercanos al 100 %, de tal forma que siempre esté disponible el tren y la infraestructura, para poder operar los servicios comerciales con normalidad. En cuanto a mantenibilidad se refiere, debe optimizarse al máximo los recursos humanos y materiales que deben invertirse, por lo que la inteligencia artificial tiene un amplio campo de aplicación, referido al campo de la industria y mantenimiento 4.0 que se expone más adelante en este trabajo. Por último, desde el punto de vista de la seguridad, se pretende seguir optimizando los procesos y las variables de control, de tal manera que cada vez se reduzca más la responsabilidad humana (fallo humano), y puedan automatizarse la mayor parte posible de las comprobaciones y chequeos de seguridad. Se trata de reducir más aun los riesgos y los potenciales fallos humanos, mediante técnicas de análisis de datos e inteligencia artificial.

Dada la importancia del concepto RAMS en el sector del transporte ferroviario (y en general en cualquier otro sector), cabe destacar la existencia de la norma EN-50126 relativa a este concepto (Institution, 2023). Es una especificación y demostración de la fiabilidad, la disponibilidad, la mantenibilidad y la seguridad (RAMS) aplicada al sector ferroviario. Representa la adaptación específica de la norma básica de seguridad EN 61508, y es de obligado cumplimiento según la normativa IRIS (International Railway Industry Standard). Es obligatoria para la protección y señalización de trenes (tecnología de señalización), para el material rodante y para las instalaciones fijas que pueden encontrarse en la infraestructura (“EN 50126 Railway RAMS Standard: Specification, Verification and Management”, 2022).




Figura 2.23: Ciclo de vida RAMS de acuerdo con la EN – 50126.

La norma aborda la definición y verificación de RAMS para todas las aplicaciones ferroviarias y a todos los niveles, en todas las fases relevantes del ciclo de vida. A modo ilustrativo, se muestra en la figura 2.23 el ciclo de vida RAMS de acuerdo con la EN – 50126.

2.1.3 EU-Rail

A nivel europeo, se viene estudiando en detalle el sector ferroviario en materia de innovación e investigación, a través de la Empresa Común para el ferrocarril europeo *Europe's Rail*, (*EU-Rail*). Pretende generar un enfoque global integrado, basada una red ferroviaria de la Unión Europea (UE) de alta capacidad, flexible, multimodal, sostenible, fiable e integrada para los pasajeros y mercancías europeos. Se enmarca dentro el programa Horizonte Europa (2020-2027), y es la sucesora de la Empresa Común *Shift2Rail*.

El objetivo de *EU-Rail* (*Europe's Rail*, 2018) es promover una red ferroviaria europea integrada de alta capacidad eliminando las dificultades provenientes de la interoperabilidad, ofreciendo soluciones para la plena integración (gestión del tráfico, vehículos, infraestructuras y servicios) y logrando una adopción y un despliegue más rápidos de las innovaciones a través de proyectos financiados. *EU-Rail* apuesta por el empleo de la digitalización y la automatización para reducir los costes de la industria ferroviaria, aumentar la capacidad y reforzar la flexibilidad y la fiabilidad.

Los objetivos de *EU-Rail* están alineados con la política de UE en cuanto a la visión de la industria ferroviaria y los retos inherentes a la transformación del sistema ferroviario. Es fundamental responder a las exigencias cambiantes de los usuarios, mejorar el rendimiento y la capacidad, reducir los costes, contribuir a un transporte más sostenible, ofrecer un enfoque armonizado de la adaptación a los cambios en la industria, conceder un papel más importante al ferrocarril en el transporte y los viajes europeos, y contribuir a una mayor competitividad de la industria de suministros ferroviarios de la UE.

Dentro de *EU-Rail*, se contemplan 5 áreas distintas de trabajo:

- Gestión del tráfico ferroviario europeo en el contexto de un sistema multimodal de transporte. Se pretende:
 - Complementar el sistema ERTMS para alcanzar una capacidad dinámica de gestión, con una operación optimizada que conlleve además un ahorro de costes.
 - Implementar una gestión de la operación de la red ferroviaria en tiempo real.
 - Apoyar al sistema ferroviario como factor determinante de la movilidad futura.
- Operación digital y automática de los trenes. Tiene como objetivo:
 - Proporcionar una arquitectura de sistemas a bordo y en tierra, adaptable y escalable, que representen la evolución en los próximos años del sistema de mando, control y señalización e incorporando los últimos avances tecnológicos.
 - Automatización escalable de las operaciones ferroviarias.
- Activos sostenibles y digitales. En esta área de trabajo, se pretende conseguir lo siguiente:
 - Soluciones para reducir la huella de carbono.
 - Mejorar la accesibilidad y aumentar la resistencia del sistema ferroviario.
 - Soluciones innovadoras para minimizar los costes del ciclo de vida de los activos.
- Transporte ferroviario ecológico, digital y competitivo. Los objetivos son claros al respecto:
 - Desarrollo e integración de nuevas soluciones operativas y tecnológicas para hacer más competitivo el transporte ferroviario de mercancías.
 - Racionalización de las operaciones de transporte de mercancías mediante la digitalización, para garantizar una integración fluida del transporte ferroviario de mercancías en el valor logístico.
- Soluciones inteligentes para líneas de tráfico de baja densidad (líneas regionales rentables). Se contempla adaptar soluciones para revitalizar y regenerar las líneas de tráfico de baja densidad, haciéndolas de baja densidad, y sostenibles desde el punto de vista económico, social y medioambiental. Para ello se deben crear conexiones sin fisuras en toda la infraestructura de transporte y, con todo ello apoyar la competitividad del sector en su conjunto.

Por tanto, todas las políticas y estrategias europeas en materia de sostenibilidad y transporte, se particularizan para el sector ferroviario a través de los objetivos de *EU-Rail* que se han expuesto en este apartado.

2.2 Aplicaciones de la inteligencia artificial a la movilidad ferroviaria

En esta sección, se analizan los problemas existentes en el sector ferroviario, estudiando los diversos casos de aplicación de las nuevas tecnologías e inteligencia artificial para la optimización de la movilidad ferroviaria en su conjunto.

De este estudio se obtienen los mayores retos a los que se enfrenta el sector, sujetos a una mayor investigación o pendientes de resolver u optimizar. También se estudian las técnicas y algoritmos de inteligencia artificial más empleados en la resolución de cada tipo de problema, la cantidad de grupos de interés involucrados en cada uno de los problemas analizados, y las áreas que requieren un mayor esfuerzo y dedicación por su alta complejidad, o por no estar siendo atendidas debido al desconocimiento o por la falta de recursos.

Este estudio está basado en la búsqueda de artículos de investigación recientes, relacionados con la temática de la tesis doctoral. Más concretamente se han estudiado artículos de investigación relacionados con la aplicación de las nuevas tecnologías y la inteligencia artificial, en los principales grupos de interés de la movilidad ferroviaria, entendida como la operación de los servicios comerciales, el mantenimiento de las infraestructuras y el mantenimiento del material rodante. Se presenta en este apartado un resumen del estudio completo que puede encontrarse en el trabajo “Estado del arte de la inteligencia artificial en el sector ferroviario poniendo en común fabricante, operadora e infraestructura” (Santos González-Llanos, 2023).

La búsqueda se ha realizado a través de las plataformas de información científica *Web of Science* (“Web of Science”, [s.f.](#)) y *Google Scholar* (“Google Scholar”, [s.f.](#)). En palabras de la Fundación Española para la Ciencia y la Tecnología, la *Web of Science*, propiedad de la empresa *Clarivate Analytics*, es la colección de bases de datos de referencias bibliográficas y citas de publicaciones periódicas, que recogen información desde 1900 hasta la actualidad. La *Web of Science* está compuesta por la colección básica *Core Collection* que abarca los índices de Ciencias, Ciencias Sociales y Artes y Humanidades, además de los *Proceedings* tanto de Ciencias como de Ciencias Sociales y Humanidades, junto con las herramientas para análisis y evaluación, como son el *Journal Citation Report* y *Essential Science Indicators*. Adicionalmente, cuenta con las bases de datos que la complementan incluidas en la licencia para España: *Medline*, *Scielo* y *Korean Citation Index* (“Web of Science”, [s.f.](#)).

Por otro lado, *Google Scholar* (o Google Académico) es un motor de búsqueda de Google, el cual busca contenido y bibliografía científica o académica. Google Scholar indexa editoriales, bibliotecas, repositorios, bases de datos bibliográficas, entre otros. Entre sus resultados se pueden encontrar citas, enlaces a libros, artículos de revistas científicas, comunicaciones y congresos, informes científico-técnicos, tesis, tesinas y archivos depositados en repositorios.

Una vez escogidos los dos motores de búsqueda de artículos científicos, se establecen una

serie de filtros para acotar el estudio en cuestión. Se pretende con ello obtener una muestra representativa del estado del arte de la movilidad ferroviaria y la aplicación de la inteligencia artificial y nuevas tecnologías al sector. Los filtros seleccionados se enumeran a continuación:

- **Fecha de publicación:** se pretenden analizar los artículos de investigación más recientes, de cara a demostrar el estado del arte más actual y las aportaciones que puede generar la presente tesis doctoral. Existe alguna excepción en la que se ha escogido algún artículo menos reciente, pero debido al interés de la aplicación investigada o el algoritmo de inteligencia artificial empleado.
- **Contenido:** los artículos escogidos deben de trabajar sobre aplicaciones del análisis de datos o técnicas de inteligencia artificial a problemas del sector ferroviario, preferentemente relacionado con la operación y el servicio de movilidad, más que con problemas logísticos o de estudios teóricos sin aplicación real definida.
- **Grupos de interés afectados:** tal y como se viene mencionando en este trabajo, se pretende estudiar la movilidad ferroviaria en su conjunto, en la que participan los grupos de interés principales que son el operador, el gestor de la infraestructura, y el fabricante y mantenedor del material rodante. Los artículos que se han seleccionado deben afectar al menos a uno de los tres grupos de interés, priorizando la selección de aquellos en los que participan más de uno. Esto permite extraer al final una visión fiable y realista de la transversalidad y globalidad con la que se están tratando los problemas y retos actuales relacionados con la movilidad ferroviaria.

De forma más concreta se muestran a continuación los términos de búsqueda empleados en cada una de las dos plataformas:

- Términos de búsqueda en *Google Scholar*:
 - Artificial Intelligence Railway.
 - Artificial Intelligence Railway Failure.
 - Artificial Intelligence Railway Fault.
 - Artificial Intelligence Railway Model.
 - Predictive Maintenance Railway.
 - Railway Artificial Intelligence Vehicle Model.
 - Deep Learning Approach Railway.
 - Deep Learning Approach Railway Vehicle Failure.
 - Condition Based Maintenance Railway Artificial Intelligence.
 - Models for Predictive Maintenance Railway.
 - Models for Predictive Maintenance Railway Track.
 - Models for Predictive Maintenance Train.
 - Predictive Maintenance Neural Network.

- Términos de búsqueda en *Web of Science*:
 - Railway AI Decision Tree.
 - Railway Neural Network.
 - Predictive Maintenance Railway Vehicle.
 - Predictive Maintenance Railway Artificial Intelligence.
 - Predictive Maintenance Railway.
 - Artificial Intelligence Railway.
 - AI Railway.
 - Artificial Intelligence and Train Transport.

Tras una búsqueda inicial aplicando los filtros mencionados, se obtiene un total de 452 artículos de investigación publicados durante los últimos años. De este número total, unos 125 artículos se han publicado muy recientemente (desde principios del año 2022). De los 125 se han escogido 72 artículos como muestra representativa, tras un último filtro en el que se han descartado artículos muy parecidos entre sí, o bien que tratan temas de logística, horarios u otra temática más alejada del núcleo de los grupos de interés mencionados.

En la tabla 2.8 se agrupan los artículos estudiados por año de publicación, con objeto de demostrar que este estudio se basa en información recientemente publicada.

Año	Artículos publicados	Porcentaje
2023	24	33,33 %
2020	15	20,83 %
2021	13	18,06 %
2022	7	9,72 %
2019	2	2,78 %
2017	2	2,78 %
2016	2	2,78 %
2010	2	2,78 %
2015	1	1,39 %
2014	1	1,39 %
2013	1	1,39 %
2012	1	1,39 %
1999	1	1,39 %

Tabla 2.8: Clasificación por año de publicación de los 72 artículos estudiados.

A continuación, se enumeran los 72 artículos estudiados con su referencia correspondiente:

Nº	Artículo
1	Alawad et al., 2020
2	Amanna et al., 2010
3	Arslan y Tiryaki, 2020
4	C. Chen et al., 2020
5	Cheremisin et al., 2017
6	Choi et al., 2020
7	Daniyan et al., 2020
8	Daniyan et al., 2022
9	Davari et al., 2021
10	De Simone et al., 2023
11	Fantini et al., 2017
12	Fumeo et al., 2015
13	Martínez-Llop et al., 2021
14	Geng et al., 1999
15	Guo et al., 2020
16	Han et al., 2020
17	Hua et al., 2020
18	Jiang y Gao, 2020
19	Kaewunruen y Osman, 2023
20	Khabarov y Volegzhanina, 2020
21	Komyakov et al., 2016
22	Kour et al., 2022
23	Kruszyna, 2022
24	Kuźnar et al., 2021
25	H. Li et al., 2014
26	Lian et al., 2022
27	Q. Liu y Huang, 2020
28	Gerum et al., 2019
29	Luque et al., 2021
30	Ma et al., 2019
31	Oh et al., 2022
32	Ersöz et al., 2022
33	Pănoiu et al., 2023
34	Pappaterra et al., 2021
35	Patwardhan et al., 2021
36	Pires et al., 2021
37	Sadeghi y Askarinejad, 2012
38	Sheng et al., 2022
39	Shu et al., 2013
40	Sikora et al., 2021
41	Singhal et al., 2020

Sigue en la página siguiente.

Nº	Artículo
42	Sresakoolchai y Kaewunruen, 2021
43	Sresakoolchai y Kaewunruen, 2021
44	Sresakoolchai et al., 2023
45	Uhl et al., 2010
46	Urda et al., 2020
47	T. Wang et al., 2020
48	Z. Wang, 2020
49	Xu y Ai, 2021
50	Yin y Zhao, 2016
51	Mulongo et al., 2021
52	H. Zhang et al., 2022
53	Açıkgöz y Korkmaz, 2023
54	Balogun y Atttoh-Okine, 2023
55	J. Chen et al., 2023
56	Martínez-Llop et al., 2023
57	Havaei y Sandidzadeh, 2023
58	Wan et al., 2023
59	G. Li et al., 2023
60	Liang et al., 2023
61	J. Liu et al., 2023
62	Lu et al., 2022
63	Luo et al., 2023
64	Abdu et al., 2023
65	Caixia et al., 2023
66	Pang y Chen, 2023
67	Pineda-Jaramillo y Viti, 2023
68	Qin et al., 2023
69	Tang et al., 2023
70	Ju y Liang, 2022
71	Yangping et al., 2022
72	J. Zhang y Zhang, 2023

Tabla 2.9: Artículos científicos estudiados para caracterizar el estado del arte de este trabajo.

Se muestran a continuación los resultados y conclusiones principales del análisis de los 72 artículos científicos mencionados, atendiendo a las siguientes categorías:

- Temática global del problema estudiado (se establecen 4 categorías generales).
- Tipo de problema resuelto.
- Tipo de tecnología o algoritmo de inteligencia artificial empleado.
- Número de grupos de interés involucrados.

Atendiendo a la temática global, se establecen cuatro temáticas diferenciadas que se recogen en la tabla 2.10, con objeto de entender las categorías globales que son de interés creciente en el ámbito de la investigación durante los últimos años.

Clasificación de los artículos por temática
Seguridad
Fiabilidad y mantenimiento
Sostenibilidad
Experiencia de usuario

Tabla 2.10: Temáticas tratadas en los artículos estudiados.

Estas temáticas resumen todos los problemas y retos a los que se enfrenta la movilidad ferroviaria en la actualidad. Pese a que esta tesis se centra en el estudio de la movilidad de viajeros, existen sinergias con el transporte de mercancías y por ello se han incorporado al estudio numerosos artículos que están relacionados con el transporte de mercancías.

En la figura 2.24, se presenta un gráfico con la clasificación de los artículos por cada uno de los bloques temáticos establecidos.




Figura 2.24: Clasificación de los 72 artículos estudiados en función de la temática global tratada.

Como puede observarse en la figura 2.24, más de la mitad de los artículos estudiados tratan sobre la optimización y mejora de la fiabilidad y la mantenibilidad, alineado con lo expuesto

en los antecedentes relativo a la necesidad creciente de investigar este campo, para conseguir mejorar notablemente la eficiencia de la operación ferroviaria de viajeros y mercancías.

El segundo campo más estudiado es la seguridad, aunque tal y como se ha mencionado anteriormente, se pretende siempre seguir optimizando y mejorando esta área para reducir los riesgos y la responsabilidad por errores humanos. Una línea de investigación existente, es la relacionada con la redundancia y automatización de supervisiones de seguridad empleando las nuevas tecnologías.

Por último, tanto la sostenibilidad como la experiencia de usuario, son campos en los que la investigación está empezando a potenciarse y tiene todavía un amplio recorrido de estudio y aplicación futura.

De forma más concreta, se han desglosado las cuatro categorías mencionadas en un total de 18 tipos de problemas estudiados, tal y como puede observarse en la tabla 2.11.

Problemática tratada en los artículos	Artículos	Porcentaje
Detección de obstáculos en vía para la seguridad	13	18,57 %
Mantenimiento predictivo de la infraestructura	10	14,29 %
Mantenimiento predictivo del material rodante	9	12,86 %
Análisis de magnitudes físicas (velocidad, fuerzas, aceleraciones,...)	5	7,14 %
Planificación, toma de decisiones y rutas	5	7,14 %
Radio y comunicaciones	4	5,71 %
Sistema eléctrico	4	5,71 %
Pasos a nivel o estaciones	4	5,71 %
Otros	4	5,71 %
Energía consumida por el material rodante	3	4,29 %
Transporte de mercancías	2	2,86 %
Metodología BIM - Building Information Modelling	2	2,86 %
Análisis de accidentes	2	2,86 %
Otros	2	2,86 %
Ciberseguridad	1	1,43 %
Experiencia del viajero	1	1,43 %
Señalización ferroviaria	1	1,43 %
Fabricación de material rodante	1	1,43 %
Perfil de velocidad	1	1,43 %

Tabla 2.11: Desglose más concreto de los problemas tratados en los artículos estudiados.

A partir del diagrama de Pareto que se muestra en la figura 2.25, se pueden extraer conclusiones como que los problemas mayormente estudiados son, los relativos a la seguridad en la detección de obstáculos en la vía y el mantenimiento predictivo, tanto de infraestructura como de material rodante. De hecho, suman casi el 50 % de los artículos analizados. Ambas temáticas están ampliamente estudiadas, y están apareciendo ya aplicaciones concretas que dan buenos resultados en distintas compañías tanto del sector público como privado. Concretamente el mantenimiento predictivo está a la orden del día de todos los fabricantes ferroviarios, y existen programas piloto con el operador para validar el funcionamiento óptimo de este nuevo modelo

de mantenimiento.

Además de estos dos temas mencionados, existen muchos otros que están siendo investigados, aunque no todos presentan un alto nivel de aplicabilidad práctica debido a su inmadurez, o porque no ofrecen ventajas notables de cara a la movilidad inteligente del futuro.

Temáticas como la ciberseguridad y las comunicaciones, dado que la tecnología está en constante evolución, sufrirán en los próximos años un interés creciente en el campo de la investigación y aplicación.

En cuanto a la señalización ferroviaria, la experiencia de usuario o el consumo de energía, necesitan un impulso en los próximos años para continuar trabajando en su optimización, dado que son variables fundamentales de la movilidad futura.




Figura 2.25: Diagrama de Pareto de los problemas tratados en los artículos estudiados.

A continuación, se analizarán las distintas técnicas de análisis de datos e inteligencia artificial que se han empleado en los distintos artículos, con objeto de conocer los algoritmos más empleados para cada tipo de problema, y comprobar la eficacia de su implementación en cada problema en cuestión.

Existen numerosas clasificaciones de las técnicas y algoritmos de inteligencia artificial. En los artículos estudiados, se han empleado mayormente técnicas de inteligencia artificial que pueden clasificarse en tres grandes grupos:

- *Machine learning*: se incluyen algoritmos de aprendizaje automático, que ayudan a construir un modelo analítico a partir de los datos que se proporcionan. Pueden ser algoritmos de aprendizaje supervisado o no supervisado, en función de si existe una variable objetivo localizada o se pretende encontrar un patrón que sigan los datos. Se incluyen análisis estadísticos o de regresión, además de redes neuronales y otros algoritmos más complejos.
- *Deep learning*: este campo puede incluirse dentro del machine learning. En el estudio se ha decidido separar las dos categorías debido a la cantidad de artículos que emplean esta técnica concreta, basada en redes neuronales de aprendizaje profundo.
- *Computer vision*: conocido también como visión artificial. Estos algoritmos son capaces a partir de imágenes, vídeos o sonidos, de detectar patrones de comportamiento en los datos aportados, y extraer así conclusiones valiosas para el fin buscado.

Atendiendo a la categorización anterior expuesta, en la tabla 2.12 se determina la cantidad de artículos que emplean cada una de las técnicas de inteligencia artificial mencionadas. Nótese que la suma total es mayor a la del número de artículos estudiados, pero se debe a que algunos de esos artículos han empleado más de una técnica de inteligencia artificial descrita.

Tecnologías	Nº artículos	Porcentaje
Machine Learning (ML)	20	28,6 %
Deep Learning (DL)	55	78,6 %
Computer Vision (CV)	19	27,1 %

Tabla 2.12: Categoría global de las técnicas de inteligencia artificial empleadas en los artículos estudiados.

A partir de los datos de la tabla anterior, cabe destacar el uso frecuente del *deep learning* como técnica de inteligencia artificial favorita, aplicada en los distintos problemas que se han estudiado.

Las redes neuronales presentan de forma general unos resultados muy positivos, esto es, con una baja tasa de error, y una eficacia suficiente para la resolución de distintos problemas de clasificación o de regresión. Estos algoritmos presentan una parte de cálculo lineal y otra de cálculo no lineal, que logran mejorar los resultados que hasta ahora se venían consiguiendo con regresiones lineales o regresiones múltiples. Problemas en los que existen grandes cantidades de datos disponibles, son favorables al uso de las redes neuronales.

En la tabla 2.13 se hace un desglose mucho más detallado de las distintas técnicas y algoritmos

de inteligencia artificial que se incluyen en las 3 categorías globales expuestas. De este modo, puede observarse el tipo concreto de algoritmo que presenta un mayor uso en los problemas planteados en los artículos científicos.

Algoritmo de Inteligencia Artificial	Nº artículos	Porcentaje
Convolutional Neural Network (DL)	14	20,0 %
Artificial Neural Networks (DL)	11	15,7 %
Optimización basada en heurísticos*	9	12,9 %
Support Vector Machines (ML)	6	8,6 %
YOLO y sus versiones (CV)	6	8,6 %
Regresión (ML)	5	7,1 %
Region Proposal Network (CV)	5	7,1 %
Back Propagation Neural Network (DL)	5	7,1 %
Recurrent Neural Network (DL)	4	5,7 %
Faster R-CNN (CV)	4	5,7 %
Long-Short Term Memory (DL)	4	5,7 %
Feature Pyramid Network (CV)	3	4,3 %
Autoencoder (DL)	3	4,3 %
Random Forest (ML)	3	4,3 %
Reinforcement Learning (ML)	2	2,9 %
Deep Neural Networks (DL)	2	2,9 %
Fuzzy Neural Networks (DL)	2	2,9 %
Radial Basis Function Networks (DL)	2	2,9 %
Generative Adversarial Networks (DL)	2	2,9 %
Cognitive Radio (ML)	1	1,4 %
Case-Based Reasoner (DL)	1	1,4 %
Deep Belief Network (DL)	1	1,4 %
Restricted Boltzmann Machine (DL)	1	1,4 %
K-nearest Neighbour algorithm (ML)	1	1,4 %
Gated Recurrent Unit (DL)	1	1,4 %
Multilayer feed-forward Network (DL)	1	1,4 %
Decision Tree (ML)	1	1,4 %
Fully-connected Neural Network (DL)	1	1,4 %
Vision Transformer (CV)	1	1,4 %
Otros	1	1,4 %

Tabla 2.13: Algoritmos concretos de inteligencia artificial empleados en los artículos estudiados.

A la vista de los resultados expuestos, se demuestra que los algoritmos de *deep learning*, concretamente las redes neuronales, son las más empleadas y las que mejores resultados ofrecen para problemas en los que se cuenta con una base de datos, de la que se pretende extraer conclusiones o un modelo de comportamiento. Otras técnicas también son ampliamente empleadas con buenos resultados como por ejemplo *Support Vector Machines*, regresiones lineales, *K-nearest Neighbour* o los árboles de decisión.

En último lugar, se analizarán los grupos de interés involucrados en cada uno de los artículos estudiados. Se pretende con ello entender si se están estudiando los problemas de manera transversal incorporando a todos los participantes, o bien alguno de ellos no está involucrado y se tiene una visión sesgada o parcial de la posible resolución del problema. Este análisis es fundamental, para poder plantear finalmente una metodología para la implantación de una movilidad inteligente.

Se recuerda que los tres grupos de interés son el operador, el administrador de la infraestructura, y el fabricante y mantenedor del material rodante. En la figura 2.26 se muestra el porcentaje de artículos estudiados que involucran a 1, 2 ó los 3 grupos de interés existentes. La suma total de los artículos asciende a 70, dado que hay dos artículos generales que tratan sobre una revisión de la literatura existente, y por tanto no trabajan un problema o una temática concreta.




Figura 2.26: Diagrama de la cantidad de grupos de interés que intervienen en cada artículo estudiado.

Como conclusión general puede observarse, como tan solo el 9% de los artículos tratan temáticas incorporando a todos los grupos de interés, siendo más del 50% de los casos en los que únicamente uno de los participantes interviene en el tratamiento y resolución de la problemática. Esto significa que no se están tratando de forma transversal los problemas y retos existentes relacionados con la movilidad ferroviaria, y por tanto esta visión sesgada y no compartida genera soluciones parciales, que se alejan de alcanzar el óptimo para todas las partes involucradas. Existe por tanto una amplia área de mejora en materia de análisis y resolución de problemas, y será uno de los puntos clave a tratar y destacar en la metodología que se determine como conclusión final de esta tesis.

El hecho de analizar el problema desde todos los puntos de vista, además de garantizar la

solución óptima, da lugar a la compartición de recursos materiales y humanos, de información y de tratamiento de la información, que logren reducir al mínimo los esfuerzos invertidos entre todas las partes.

En la figura 2.27 se muestran todas las combinaciones posibles de los distintos grupos de interés con el número concreto de artículos correspondientes a cada combinación.




Figura 2.27: Artículos clasificados por los grupos de interés concretos que intervienen en cada caso de estudio.

En las tablas 2.14 y 2.15 se muestran los datos expuestos en las figuras 2.26 y 2.27. Se concluye de igual forma que existe una necesidad imperiosa de tratar los problemas desde todos los puntos de vista, para tratar de optimizar y ser eficientes en la resolución de los retos planteados para la futura movilidad inteligente. Deben participar por tanto los tres grupos de interés, para poder validar la solución de cualquiera de los problemas que se traten.

Nº grupos de interés	Cantidad de artículos	Porcentaje
1	37	52,9 %
2	27	38,6 %
3	6	8,6 %

Tabla 2.14: Número de grupos de interés involucrados en cada uno de los artículos estudiados.

Grupo(s) de interés involucrado(s)	Cantidad de artículos	Porcentaje
Operadora	6	8,57 %
Fabricante	12	17,14 %
Infraestructura	19	27,14 %
Operadora + Infraestructura	15	21,43 %
Operadora + Fabricante	7	10,00 %
Fabricante + Infraestructura	5	7,14 %
Operadora + Fabricante+ Infraestructura	6	8,57 %

Tabla 2.15: Desglose de cada grupo de interés que interviene en los artículos estudiados.

La mayor parte de los artículos, tratan de forma aislada problemáticas relacionadas con la infraestructura. Una explicación posible, puede deberse a la mayor inversión en la construcción y mantenimiento de todos los elementos incluidos en la infraestructura. Le sigue a este porcentaje los estudios que involucran a operador y administrador de infraestructuras, generalmente ambos pertenecientes al sector público. En tercer lugar, se encuentran todos los estudios relacionados de forma aislada con el fabricante y mantenedor de material rodante.

Es suficiente este análisis para asegurar que, no se están tratando los retos y problemas de la movilidad ferroviaria desde todos los puntos de vista, y que se tratan de forma totalmente aislada. El fabricante y mantenedor de material rodante trabaja de forma aislada por su lado. Y el operador y administrador de la infraestructura, de la misma forma trabaja de forma aislada por su lado también. Cabe destacar que suele existir mayor sinergia entre operador y administrador de infraestructura dado que, suelen pertenecer al sector público y por tanto suelen ser propiedad del estado.

Por último, en lo que se refiere al estado del arte de la predicción de movilidad, cabe destacar que existen muchas propuestas y proyectos de publicación y estudio de los datos de movilidad de las personas. Estos estudios, suelen basarse en contratos con compañías de teléfonos móviles. Pero se conocen muy pocos trabajos de investigación relevantes o destacados que traten sobre la aplicación de las nuevas tecnologías y la inteligencia artificial, para la predicción de la movilidad de las personas o mercancías, siendo uno de los más destacados un artículo impulsado por la Universidad Nacional de Colombia (Rodríguez-Rueda y Turias, 2017). Por ello, en el capítulo de desarrollo se profundizará sobre un modelo de predicción de movilidad, que puede resultar de interés para el estado del arte de la movilidad inteligente. Es fundamental para entender la movilidad futura, y así poder planificar con antelación y de forma óptima todos los servicios de transporte.

Capítulo 3

Objetivos y metodología

En este capítulo, una vez conocido el estado del arte de las aplicaciones de la inteligencia artificial a la movilidad ferroviaria, y los retos a los que se enfrenta la movilidad del futuro a través de programas como el de *EU-Rail*, se establecen de forma específica y clara los objetivos de esta tesis doctoral, al igual que la metodología propuesta para alcanzarlos.

3.1 Objetivos

El objetivo principal de esta tesis doctoral, es proponer una metodología para la aplicación de la inteligencia artificial con objeto de optimizar la movilidad ferroviaria, de cara a ser implementada en los próximos años, tanto a nivel regional como nacional.

Dicha metodología se apoya en el empleo de técnicas de análisis de datos e inteligencia artificial, para poder optimizar el modelo general de movilidad de personas. Se particularizará en el sector ferroviario por afinidad profesional del autor, aunque la metodología es de aplicación a cualquier medio de transporte. Se pretende además que los retos y problemas se analicen desde un punto de vista global, esto es, desde la perspectiva de todos y cada uno de los actores principales en la movilidad ferroviaria: operador, administrador de infraestructura, y fabricante y mantenedor de los vehículos ferroviarios.

Se han realizado numerosos estudios hasta la fecha que muestran un análisis de los problemas de manera aislada, pero muy pocos se han estudiado globalmente teniendo en cuenta a todos los participantes, tal y como se demuestra en el apartado del estado del arte.

Como objetivos secundarios, esta tesis pretende:

1. Preparar una metodología de optimización que pueda extrapolarse a la movilidad inteligente de mercancías, cambiando las variables de entrada y las condiciones de contorno, pero con la misma idea base y los mismos pasos lógicos a seguir.
2. Servir como base para un estudio futuro de movilidad conjunta de todos los medios de transporte, de tal manera que a nivel de viajeros se cree un único modelo globalizado multimodal.

3. Servir como base para un estudio de movilidad inteligente de mercancías empleando igualmente el transporte multimodal.
4. Activar a las instituciones públicas para poder predecir la demanda de transporte tanto de viajeros como de mercancías, de tal manera que se trabaje desde las instituciones responsables, en adaptar la oferta de los distintos medios de transporte a dicha demanda predicha.
5. Introducir aplicaciones reales y robustas de la inteligencia artificial, en instituciones tanto públicas como privadas. Más concretamente, se presentan aplicaciones relacionadas con el sector ferroviario y el mantenimiento predictivo, como una de las áreas más susceptibles de ser optimizadas.
6. Dar uso a la gran cantidad de datos que se generan a diario, tanto a nivel público como a nivel privado. La mayor parte de esos datos son accesibles en abierto y pueden descargarse de las distintas webs de organismos públicos.
7. Fomentar la compartición de los datos entre las distintas entidades involucradas en un mismo servicio (movilidad), proponiendo un caso de éxito para todas las partes si se comparten de manera transparente los datos que recoge cada uno desde su perspectiva o función.
8. Reducir los recursos humanos y materiales para la obtención de los datos (sensores, captadores...). Si se analizan de forma conjunta los problemas, se podrá encontrar la mínima cantidad de información que es necesario recoger para la aplicación en cuestión. No se trata de obtener muchos datos, sino los adecuados para el fin que se persigue.
9. Contribuir con la optimización de recursos humanos y materiales (y por tanto económicos) en la estrategia futura de un modelo global de movilidad inteligente en el que las distintas áreas y regiones deberían estar trabajando.
10. Contribuir con la evolución tecnológica de la movilidad alineada con las políticas y directrices europeas, fomentando el transporte ferroviario de personas y mercancías como medio de transporte más eficiente, seguro y sostenible.
11. Contribución con el medio ambiente a través de la reducción de emisiones, la eficiencia energética y la sostenibilidad tal y como marca la Agenda 2030 a través de los ODS (objetivos de desarrollo sostenible).
12. Distribuir y divulgar los distintos objetivos contenidos en *EU-Rail* como guía futura del sector ferroviario en materia de movilidad.

3.2 Metodología

En este apartado se describe la metodología seguida en la tesis doctoral, esto es, los pasos que se han dado durante toda la investigación, para finalmente proponer un proceso metodológico que se recomienda seguir en el futuro para optimizar la movilidad existente en un área, región o país, tanto para el transporte de mercancías como de viajeros.

Una vez realizada la **Introducción** de este trabajo, en el capítulo de **Estado del arte**, se expone en primer lugar, como antecedentes, un estudio de la movilidad en Europa y España tanto de viajeros como de mercancías. Se realiza una comparación entre los distintos modos de transporte tanto a nivel nacional como a nivel internacional. De este modo, se determinan qué medios de transporte se han usado más durante los últimos años, y en qué posición se encuentra España frente a Europa en la movilidad de viajeros y mercancías durante estos últimos años. Esta información es relevante como variable de entrada de la metodología de movilidad inteligente que se quiere plantear en este trabajo. En una segunda parte de los antecedentes, se resume también qué características se le viene exigiendo a un servicio de transporte eficiente y seguro. Con esto se pretende analizar qué fortalezas existen y se deben mantener, y qué campos de mejora hace falta atender con ayuda de las nuevas tecnologías con objeto de instaurar una movilidad inteligente, eficiente y segura. Por último, se exponen los objetivos que persigue *EU-Rail* como guía base europea sobre el futuro de la movilidad y del transporte particularizado en el sector ferroviario.

En una segunda parte del capítulo de **Estado del arte**, se presenta un estudio completo de los retos y problemas más recientes que se han trabajado hasta la fecha dentro del contexto de la movilidad ferroviaria empleando las nuevas tecnologías y, más concretamente, la inteligencia artificial. Se clasifican los tipos de problemas y las clases de algoritmos y técnicas empleadas. Igualmente, se determina la globalidad y transversalidad con la que se han tratado dichos retos, analizando si han participado de manera conjunta los tres actores principales que intervienen en la movilidad ferroviaria (el operador, el administrador de infraestructuras y el fabricante y mantenedor del material rodante), o si por el contrario se han tratado los problemas de manera aislada o con algún grupo de interés ausente.

En el capítulo de **Resultados y discusión**, se presentan tres partes bien diferenciadas. En una primera parte, se expone el estudio de movilidad realizado entre provincias en España para entender las necesidades de movilidad del país, y por tanto conocer de primera mano cómo necesita moverse la población. Esta información representa la demanda actual de transporte por parte de los ciudadanos españoles.

En una segunda parte, se expone un estudio de los servicios de transporte existentes entre provincias de España. Esto se conoce como la oferta de transporte existente de cara a los ciudadanos.

Una vez conocida esta información, en una tercera parte, se procede a aplicar la inteligencia artificial para optimizar la movilidad en su conjunto, y lograr así acercar la oferta y la demanda lo máximo posible. Se presentan cinco casos de éxito. En uno se trabaja en la predicción de los desplazamientos de las personas. En el resto de los casos, se presentan campos aplicados al mantenimiento predictivo tanto del material rodante como de la infraestructura, por ser uno de los campos más susceptibles de ser optimizados por el alto impacto económico y energético que posee dentro del ciclo de vida completo. Se emplea inteligencia artificial como herramienta fundamental para optimizar cada una de las áreas mencionadas:

1. **Operación:** se realiza una predicción de la movilidad entre distintas ciudades empleando los datos de acceso público que publica en abierto el Ministerio de Transportes, Movilidad y Agenda Urbana [28]. De este modo se podrá ajustar más la oferta de los servicios de

transporte y la demanda de los usuarios.

2. **Infraestructura:** se emplean redes neuronales recurrentes para poder predecir un comportamiento anómalo de un puente, ante el paso de los trenes debido a condiciones climáticas extremas (lluvias torrenciales en este caso concreto), con objeto de poder conocer con antelación un posible riesgo de operación y poder tomar las medidas necesarias para evitar el riesgo asociado.
3. **Fabricante y mantenedor del material rodante:** se presentan tres casos de éxito en los que se logra predecir un comportamiento anómalo o degradado de algún componente ferroviario. En dos de los casos se trabaja con la predicción de un comportamiento anómalo de la amortiguación del tren que causa aceleraciones excesivas percibidas por el viajero. No se llegan a alcanzar los valores límites de seguridad, a partir del cual se limitaría la velocidad de circulación del tren, pero sí causa una clara pérdida de confort en los viajeros. Mediante el uso de redes neuronales se detectará esta degradación del comportamiento dinámico de la estructura del tren, con antelación suficiente antes de que cause problemas de confort serios o incluso llegue a los valores límites de seguridad mencionados. En el tercer caso realiza un estudio de predicción de fallo de un rodamiento ferroviario a partir del estudio de la evolución de las temperaturas de los rodamientos a lo largo del tiempo. De igual modo, se logra predecir un comportamiento atípico y se detecta un potencial fallo antes de que ocurra en servicio comercial, con el consiguiente impacto económico que conlleva y la limitación de velocidad que se puede imponer debido a este fallo.

Al final de este capítulo se resumen las posibles sinergias que pueden encontrarse entre los tres grupos de interés que intervienen en la movilidad ferroviaria, como preámbulo al apartado de conclusiones y líneas futuras, donde se recomiendan los siguientes pasos a dar para continuar con esta línea de trabajo que queda abierta.

En la sección de **Conclusiones**, se exponen las conclusiones principales obtenidas tras haber realizado los estudios mencionados en los anteriores capítulos. Como parte final de estas conclusiones, se presenta la metodología recomendada para optimizar una movilidad inteligente. Este es el entregable más relevante de esta tesis doctoral. Se pretende entender las necesidades reales de la movilidad, para poder analizar los servicios de transporte ofertados y poder aplicar inteligencia artificial para la optimización de la operación y del mantenimiento, en especial, aplicando el mantenimiento predictivo. Para ello, es indispensable compartir la información y los datos entre los grupos de interés. Se deberá extraer inteligencia de estos datos, aprovechando las ventajas claras que aportan las nuevas tecnologías a través de los distintos algoritmos de inteligencia artificial, tal y como se ha demuestra en los casos de éxito.

En la sección de **Líneas futuras**, se resumen las líneas de investigación que quedan abiertas o que se recomienda explorar y que dan continuidad a este trabajo, con objeto de seguir evolucionando hacia una movilidad inteligente, eficiente y segura.

Capítulo 4

Resultados y discusión

En este capítulo se desarrolla el núcleo principal de esta tesis doctoral, que generará como resultado el planteamiento de una metodología para la implantación de una movilidad inteligente en una región o país. Dicha metodología, con carácter general, podrá aplicarse a cualquier medio de transporte e incluso a la totalidad del transporte público, creando en su conjunto una movilidad global inteligente. El estudio gira entorno a la movilidad ferroviaria, no solamente por afinidad profesional del autor, sino porque se pretende potenciar el transporte ferroviario frente a la carretera o al avión en un el ámbito nacional. Esta idea, tal y como se ha mencionado anteriormente en este trabajo, proviene de las directrices europeas en materia de sostenibilidad y eficiencia energética.

Se presentan tres partes bien diferenciadas en este capítulo.

En una primera parte, se desarrolla un estudio de movilidad realizado a partir de los datos aportados por el gobierno, con objeto de conocer cómo se mueve la población entre las distintas provincias de España. El método empleado, se puede extrapolar a la movilidad entre cualquier región o área siguiendo los mismos pasos lógicos, pero empleando los datos adecuados en cada caso. Esta parte responde a **cómo necesita moverse** la población entre provincias en España, esto es, la demanda real de transporte que existe en España hoy en día.

A continuación, en una segunda parte, se expone para cada provincia y trayecto las opciones de movilidad existentes en la actualidad, comparando los distintos modos de transporte. De esta manera, se pretende entender **cómo puede moverse** la población entre provincias en España, con la oferta de servicios de transporte que existe.

Esta información (oferta y demanda) son de gran relevancia para entender la movilidad en su conjunto, y para poder planificar la operación ferroviaria y la explotación de las líneas de una manera ajustada en términos económicos y energéticos. Además, se logrará cumplir con el objetivo social de ofrecer un servicio adecuado de transporte a la población, de acuerdo a la demanda estudiada.

En una tercera parte, se presentan ejemplos de aplicación claros con el objetivo de optimizar la movilidad ferroviaria en términos energéticos y económicos, mediante la aplicación de la inteligencia artificial.

El primero de los casos estudiados trata de predecir la demanda de transporte solicitada por la población, con objeto de aumentar la precisión de las curvas de oferta y demanda, y trabajar con datos más fiables, robustos y exactos. De este modo, se podrán establecer soluciones de transporte más ajustadas a la situación real de la movilidad.

El resto de los casos, se centran en la optimización de la operación ferroviaria, más concretamente, del área de mantenimiento. En el ciclo de vida de un tren o de una infraestructura ferroviaria, el mantenimiento ocupa la mayor parte del mismo. Esto viene reflejado en la distribución de los gastos de capital (CapEx), que suelen estar cerca del 40 %, frente a los gastos de operación (OpEx), que suelen alcanzar valores del 60 %. Por tanto, el mantenimiento del material rodante y de las infraestructuras es esencial en materia de inversión de costes y energía, por lo que su optimización es de gran relevancia para el sector. Aplicando además diferentes técnicas de inteligencia artificial, se logran resultados muy positivos que conllevarán ahorros importantes por la monitorización en tiempo real de ciertas variables de seguridad del tren. Esto pertenece al campo del mantenimiento predictivo, área que se viene trabajando en el sector desde hace años, pero con mucho margen de explotación, mejora y optimización en los próximos años.

En estos casos que se exponen, se aplica la inteligencia artificial en la operación, en la infraestructura y en el material rodante, creando por tanto un contexto cercano al nuevo concepto de movilidad inteligente al involucrar a todos los grupos de interés. Esta tercera parte responde a la pregunta **cómo optimizar al máximo** los recursos materiales y humanos existentes, logrando una mejor adaptación de la oferta y la demanda en cuanto al transporte se refiere.

Estos pasos lógicos se resumen en el siguiente diagrama presentado en la figura 4.1.




Figura 4.1: Diagrama de los tres bloques lógicos de la metodología de movilidad inteligente propuesta.

Para cerrar este capítulo, se expone al final la metodología concreta mencionada para la optimización de una movilidad inteligente que pueda ser aplicable a cualquier región o área, siendo de obligado cumplimiento que participen los tres grupos de interés en cada uno de los problemas futuros que se planteen en materia de movilidad.

4.1 Estudio de la movilidad entre provincias de España (demanda)

En este apartado se estudia la movilidad de las personas entre cada una de las provincias de España, es decir, se pretende entender en primer lugar cómo necesita la población moverse. Esta información permite conocer la demanda real de movilidad entre provincias.

A continuación, se presentan los datos empleados para dicho estudio.

4.1.1 Descripción de los datos empleados en el estudio

Los datos empleados en este estudio han sido proporcionados por el Ministerio de Transportes Movilidad y Agenda Urbana (MITMA). Existe una base de datos abierta al público en su página web oficial, que contiene toda la información de los desplazamientos que realizó la población en España desde febrero de 2020 hasta abril de 2021 (“Open Data Movilidad | Ministerio de Transportes, Movilidad y Agenda Urbana”, [s.f.-b](#)).

La obtención de estos datos se ha realizado a través de un contrato específico del gobierno con compañías de telefonía móvil, siendo indispensable para su publicación el cumplimiento de la Ley de Protección de Datos personales y garantía de los derechos digitales, la Ley Orgánica 3/2018, de 5 de diciembre (rodriguez-2020).

En la página web mencionada, existe un espacio compartido con estos datos de movilidad. Estos datos se publican en abierto con el objetivo de fomentar la participación ciudadana, el desarrollo económico, la eficiencia y la transparencia en palabras del MITMA. Se pueden emplear para hacer distintas aplicaciones de diversa utilidad, y para generar servicios o nuevos negocios. Los datos han sido estructurados según el tipo de estudio y según la zonificación. Existen tres zonas diferenciadas: los distritos, los municipios y las grandes áreas urbanas (esta última clasificación recientemente añadida).

La base de datos se organiza por niveles. El primer nivel está dividido en 4 carpetas. Dos carpetas se corresponden con la denominación *Maestra 1*, que contiene las matrices de los desplazamientos, y monitoriza y agrupa los viajes por distritos o municipios (*Maestra 1 - Distritos*; *Maestra 1 - Municipios*). Las otras dos carpetas se corresponden con la denominación *Maestra 2*, e incluye las matrices de desplazamientos por persona, dividido a su vez por distritos y municipios como en el primer caso. En un segundo nivel, la información se organiza por tiempos, esto es, por meses completos o por días. Los archivos pueden estar en formato ‘.csv’ o bien en formato ‘.gz’ para lo cual necesitan ser descomprimidos.

En la figura 4.2 se presenta un pantallazo del contenido de la *Maestra 1 - Distritos*, que contiene como puede observarse la fecha del desplazamiento, origen, destino, la actividad de origen, la actividad de destino (si se conoce), residencia, la edad (no se conoce), periodo del día (hora), distancia recorrida (en rangos de km), el número de viajes y el número de viajes –kilómetro. La actividad de destino no suele completarse. El periodo del día indica por horas en qué momento se ha realizado el desplazamiento.

El origen y el destino presentan un código que puede consultarse para saber de forma concreta a qué distrito se hace alusión dentro de una provincia determinada. Estos códigos se encuentran asimismo en las mismas carpetas de los datos aportados por el MITMA.

fecha	origen	destino	actividad_origen	actividad_destino	residencia	edad	periodo	distancia	viajes	viajes_km
20200221	01001_AM	01001_AM	casa	otros	01	NA	00	0005-002	4.350	8.659
20200221	01001_AM	01001_AM	casa	otros	01	NA	00	002-005	9.775	33.090
20200221	01001_AM	01001_AM	casa	otros	01	NA	01	005-010	6.235	56.873
20200221	01001_AM	01001_AM	casa	otros	01	NA	03	002-005	4.350	17.387
20200221	01001_AM	01001_AM	casa	otros	01	NA	03	005-010	4.350	27.336
20200221	01001_AM	01001_AM	casa	otros	01	NA	03	010-050	15.398	228.776
20200221	01001_AM	01001_AM	casa	otros	01	NA	04	005-010	9.775	82.826
20200221	01001_AM	01001_AM	casa	otros	01	NA	05	002-005	4.350	10.290

Figura 4.2: Datos de los archivos *Maestra 1 - Distrito* de los datos del MITMA (“Open Data Movilidad | Ministerio de Transportes, Movilidad y Agenda Urbana”, [s.f.-b](#)).

En la figura 4.3 se presenta un pantallazo del contenido de la *Maestra 1 - Municipios*, que contiene información muy similar, aunque no contiene información de la edad o de la actividad correspondiente, lo cual no afecta en este estudio dado que es información irrelevante para el

mismo.

```

fecha|origen|destino|periodo|distancia|viajes|viajes_km
20200221|01001_AM|01001_AM|00|0005-002|8.700|16.545
20200221|01001_AM|01001_AM|00|002-005|29.627|87.800
20200221|01001_AM|01001_AM|00|005-010|5.382|32.671
20200221|01001_AM|01001_AM|00|010-050|16.206|196.664
20200221|01001_AM|01001_AM|01|005-010|22.328|166.005
20200221|01001_AM|01001_AM|02|005-010|18.393|130.593
20200221|01001_AM|01001_AM|02|010-050|28.099|518.697

```

Figura 4.3: Datos de los archivos *Maestra 1 – Municipios* de los datos del MITMA (“Open Data Movilidad | Ministerio de Transportes, Movilidad y Agenda Urbana”, [s.f.-b](#)).

Por otro lado, a modo ilustrativo, se presentan en las figuras 4.4 y 4.5 las matrices *Maestra 2 – Distritos* y *Maestra 2 – Municipios*, en las que aparece una menor cantidad de información: la fecha en la que se produce el desplazamiento, el distrito correspondiente con el código asignado, el número de viajes y las personas que se desplazan.

```

fecha|distrito|numero_viajes|personas
20200221|01001_AM|0|2296.359
20200221|01001_AM|1|209.913
20200221|01001_AM|2|1898.217
20200221|01001_AM|2+|3944.864
20200221|01002|0|3357.881
20200221|01002|1|663.189
20200221|01002|2|1921.721

```

Figura 4.4: Datos de los archivos *Maestra 2 – Distritos* de los datos del MITMA (“Open Data Movilidad | Ministerio de Transportes, Movilidad y Agenda Urbana”, [s.f.-b](#)).

```

fecha|origen|numero_viajes|personas
20200221|01001_AM|0|2296.359
20200221|01001_AM|1|209.913
20200221|01001_AM|2|1898.217
20200221|01001_AM|2+|3944.864
20200221|01002|0|3357.881
20200221|01002|1|663.189

```

Figura 4.5: Datos de los archivos *Maestra 2 – Municipios* de los datos del MITMA (“Open Data Movilidad | Ministerio de Transportes, Movilidad y Agenda Urbana”, [s.f.-b](#)).

Dado que los datos contenidos en las matrices *Maestra 2* son muy limitados, y no contienen toda la información relevante necesaria para este estudio, se descartarán dichas matrices como base de datos a emplear.

En cuanto a las matrices *Maestra 1*, existe la posibilidad de emplear las que contienen información sobre los distritos o las que contienen información sobre los municipios. Debido a

que este estudio se centra en la movilidad entre provincias, y puesto que los distritos contienen información mucho más detallada de lo necesario, se decide finalmente usar las matrices *Maestra 1 – Municipios*, de tal manera que pueden fácilmente agruparse los desplazamientos por provincias agrupando los códigos de dichos municipios.

Los archivos *Maestra 1 – Municipios* contienen la siguiente información:

- **Fecha:** día, mes y año en el que se producen los desplazamientos.
- **Origen y destino:** municipios concretos de origen y destino de dichos desplazamientos, estando codificados según el INE (INE - Instituto Nacional de Estadística, [s.f.](#)).
- **Periodo:** franja horaria en la que se produce el desplazamiento. Se agrupan los desplazamientos por horas completas, abarcando desde el minuto *00* al minuto *59*.
- **Distancia:** distancia recorrida por cada desplazamiento clasificada en rangos de kilómetros, a saber:
 - a. 0,5 – 2 km
 - b. 2 – 5 km
 - c. 5 – 10 km
 - d. 10 – 50 km
 - e. 50 – 100 km
 - f. >100 km
- **Viajes:** número de personas que se han desplazado.
- **Viajes – kilómetro:** consiste en multiplicar el número de desplazamientos realizados por la distancia de cada uno de los viajes, tomando como referencia la distancia media recorrida en cada uno de los desplazamientos de cada agrupación.

Dado que este estudio se centra en la movilidad entre las distintas provincias lo que se ha realizado es una agrupación de los distintos municipios pertenecientes a cada provincia. De este modo se tendrá globalmente el número de desplazamientos entre cada una de éstas.

4.1.2 Datos de la movilidad entre provincias (demanda)

Este primer estudio se realizó con los datos que había disponibles en el momento de su elaboración (verano de 2021). Estos datos comprendían desde febrero del año 2020 hasta abril del año 2021. Sin embargo, debido a la presencia del COVID-19, la movilidad se vio gravemente afectada desde febrero del año 2020 hasta julio del año 2020. Por ello, este subconjunto de datos ha sido extraído para el estudio en cuestión, de tal forma que no se vea distorsionada la movilidad global por un hecho aislado como el COVID – 19, que claramente tuvo un alto impacto en este sentido.

Por otro lado, el MITMA ha publicado recientemente una mayor cantidad de datos que comprenden desde el año 2019 hasta la actualidad de 2023. Este trabajo se empezó años atrás, y dado que se pretende proponer una metodología de trabajo para implantar una movilidad

inteligente, lo importante en cuestión es validar esta metodología, más que haber realizado el estudio con los datos más recientes hoy en día.

Los resultados que se muestran a continuación están basados en los datos disponibles desde agosto de 2020 hasta abril de 2021. Hay una cantidad suficiente de datos para estudiar la movilidad, aunque en líneas futuras se recomendará realizar este mismo estudio con una mayor cantidad de datos y más actualizados.

Se presenta de forma particular la movilidad entre las provincias de Madrid, Barcelona, Jaén, Cuenca, Valencia y Toledo. Concretamente, para cada una de ellas se muestra el porcentaje de desplazamientos que hay a otras provincias, de tal manera que pueda conocerse la movilidad real de la población en cada provincia. Esto puede consultarse en las tablas 4.1, 4.2, 4.3, 4.4, 4.5 y 4.6. Se muestra además un mapa de calor representativo en cada caso en las figuras 4.6, 4.7, 4.8, 4.9, 4.10 y 4.11.

Al final del trabajo, en el **Anexo 1**, se pueden encontrar todas las tablas y mapas de calor correspondientes a las demás provincias. Los detalles de este estudio particular y la elaboración en detalle del mismo pueden consultarse en (Fariñas Nubla, [2021](#)).

A pesar de que los datos se acotan aun número limitado de años, actualmente se han publicado una mayor cantidad de estos datos por parte del MITMA. Cuanto mayor sea la cantidad de datos disponibles, tras un tratamiento y limpieza adecuados de los datos, mejores son los resultados que pueden dar los algoritmos empleados para la predicción.

Se exponen los casos particulares mencionados, dado que pueden considerarse una muestra representativa de los diferentes casos que existen:

- Madrid y Barcelona son las dos ciudades principales de España, y cuentan con un gran flujo de viajeros por motivos profesionales y además turísticos.
- Jaén es una ciudad en la que la industria ha decaído mucho, y por tanto el flujo de viajeros. Y además, no dispone de una buena red de transporte público.
- Cuenca es una ciudad que se encuentra de paso a otras tanto para las carreteras principales como para el tren de alta velocidad.
- Valencia es un destino final muy frecuentado por motivos profesionales pero sobre todo turísticos. Cuenta con una buena conexión mediante alta velocidad ferroviaria.
- Toledo es una ciudad que cuenta con un gran flujo de viajeros diarios por motivos de trabajo, dado que tiene conexión de alta velocidad con Madrid en aproximadamente media hora. Por lo que existen muchas personas que residen en Toledo y que trabajan en Madrid. Además, es una ciudad histórica con alto atractivo turístico.

Origen	Destino	Desplazamientos (%)
Madrid	Toledo	41,76
Madrid	Guadalajara	22,99
Madrid	Ávila	3,89
Madrid	Segovia	3,5
Madrid	Ciudad Real	2,98
Madrid	Cuenca	2,29
Madrid	Valencia	1,75

Tabla 4.1: Porcentaje de desplazamientos desde Madrid a otras provincias.




Figura 4.6: Mapa de calor del porcentaje de desplazamientos desde Madrid a otras provincias.

Origen	Destino	Desplazamientos (%)
Barcelona	Girona	45,48
Barcelona	Tarragona	29,84
Barcelona	Lérida	9,74
Barcelona	Zaragoza	2,31
Barcelona	Madrid	1,8
Barcelona	Valencia	1,67
Barcelona	Baleares	1,36

Tabla 4.2: Porcentaje de desplazamientos desde Barcelona a otras provincias.




Figura 4.7: Mapa de calor del porcentaje de desplazamientos desde Barcelona a otras provincias.

Origen	Destino	Desplazamientos (%)
Jaén	Granada	31,7
Jaén	Córdoba	29,59
Jaén	Málaga	6,3
Jaén	Ciudad Real	5,15
Jaén	Madrid	5,11
Jaén	Sevilla	4,9
Jaén	Almería	3,29

Tabla 4.3: Porcentaje de desplazamientos desde Jaén a otras provincias.




Figura 4.8: Mapa de calor del porcentaje de desplazamientos desde Jaén a otras provincias.

Origen	Destino	Desplazamientos (%)
Cuenca	Albacete	31,97
Cuenca	Madrid	18,7
Cuenca	Valencia	13,33
Cuenca	Toledo	12,69
Cuenca	Ciudad Real	8,26
Cuenca	Guadalajara	6,44
Cuenca	Alicante	1,46

Tabla 4.4: Porcentaje de desplazamientos desde Cuenca a otras provincias.




Figura 4.9: Mapa de calor del porcentaje de desplazamientos desde Cuenca a otras provincias.

Origen	Destino	Desplazamientos (%)
Toledo	Madrid	76,84
Toledo	Ciudad Real	8,06
Toledo	Cuenca	3,06
Toledo	Ávila	2,96
Toledo	Cáceres	2,64
Toledo	Guadalajara	0,9
Toledo	Albacete	0,65

Tabla 4.5: Porcentaje de desplazamientos desde Toledo a otras provincias.




Figura 4.10: Mapa de calor del porcentaje de desplazamientos desde Toledo a otras provincias.

Origen	Destino	Desplazamientos (%)
Valencia	Alicante	35,82
Valencia	Castellón	32,49
Valencia	Albacete	4,59
Valencia	Cuenca	4,15
Valencia	Madrid	3,97
Valencia	Murcia	3,73
Valencia	Barcelona	2,28

Tabla 4.6: Porcentaje de desplazamientos desde Valencia a otras provincias.




Figura 4.11: Mapa de calor del porcentaje de desplazamientos desde Valencia a otras provincias.

A partir de toda la información anterior, se obtiene la demanda real existente de movilidad entre las distintas provincias. Es la base para poder plantear un servicio de transporte público de calidad y adaptado a las necesidades reales de las personas.

4.2 Servicios de transporte entre provincias de España (oferta)

Una vez conocidas las necesidades de la población en cuanto a movilidad se refiere, es decir, la demanda de movilidad existente, se procede a estudiar la oferta actual de los servicios de transporte. Entendemos por oferta de movilidad, a la infraestructura y los servicios de los distintos medios de transporte públicos y accesibles para la población.

A partir de los datos anteriores, se procede a estudiar los trayectos resultantes tras un análisis de Pareto (Johnson, 1937).

Para cada una de las provincias, se analizan los destinos existentes hasta alcanzar el 80 % de los viajes con origen en dicha provincia. Es decir, se obtiene la información de dónde viaja el 80 % de las personas de cada provincia. Se considera un estudio completo si el 80 % de los desplazamientos existentes por provincias están contemplados y optimizados, dado que carece de sentido optimizar el 100 % de los trayectos por motivos económicos.

En el caso específico de Madrid se tendrán en cuenta los desplazamientos del recuadro rojo de la figura 4.12, dado que conforman el 80 % de los desplazamientos que se producen con origen en Madrid. Este mismo trabajo se realiza con todas las provincias.

ORIGEN	DESTINO	VIAJES %
Madrid	Toledo	41,76
Madrid	Guadalajara	22,99
Madrid	Avila	3,89
Madrid	Segovia	3,5
Madrid	C. Real	2,98
Madrid	Cuenca	2,29
Madrid	Valencia	1,75
Madrid	Alicante	1,41
Madrid	Caceres	1,19
Madrid	Barcelona	1,15
Madrid	Valladolid	1,1
Madrid	Granada	0,43
Madrid	Baleares	0,43
Madrid	Vizcaya	0,43
Madrid	La Coruña	0,41
Madrid	Cordoba	0,38
Madrid	Navarra	0,36
Madrid	Pontevedra	0,35
Madrid	Soria	0,34
Madrid	Las Palmas	0,32
Madrid	Almería	0,32
Madrid	Castellón	0,31
Madrid	Guipuzcua	0,27

Figura 4.12: Localización del 80 % de los desplazamientos con origen en Madrid.

Para cada uno de los trayectos resultantes de la aplicación de la Ley de Pareto, se estudia la oferta de servicios de transporte existente en materia de tiempos y costes. De este modo, se puede realizar posteriormente un estudio comparativo entre los distintos medios de transporte, en cada uno de los trayectos estudiados.

La oferta de servicios de transporte contiene:

- Tiempos y costes viajando en coche (carretera).

- Tiempos y costes viajando en tren (si es posible).
- Tiempos y costes viajando en avión (si es posible).
- En algún caso se ha añadido posibilidad de combinación de varios transportes.

En este estudio no se contempla como opción el autobús, dado que se pretende fomentar el empleo del ferrocarril frente a la carretera. Un autobús tarda más tiempo que un coche particular en llegar al destino, aunque el coste es mucho más económico. Lo que sí que se contempla en este estudio es el viaje en avión, dado que en tiempos reales de viajes siempre gana al ferrocarril, pero no en materia de costes. Además, se está limitando su uso interno en los países y entre regiones en un entorno de hasta los 800 kilómetros (Lecca, 2023; Reiter et al., 2022).

La información anterior es muy relevante para determinar si la oferta de movilidad es óptima y útil para los usuarios. O, por el contrario, puede ayudar a determinar si no se está ofreciendo un transporte público competitivo en materia de tiempos y costes, de tal forma que el viajero se pueda plantear usarlo.

En los trayectos en los que el menor tiempo y coste resulta ser el coche particular significa que no existe un buen servicio de transporte que cubran dicho trayecto. No se está fomentando por tanto el uso del transporte público y no cumple su labor social.

En los trayectos en los que el ferrocarril sea más económico y tarde menos, se está consiguiendo una oferta adecuada para la población en ese trayecto, por lo que será sencillo fomentar el uso del transporte público entre provincias.

El objetivo en materia de movilidad de un país como España, debería ser garantizar la accesibilidad a un servicio de transporte en el que, a cualquier ciudadano, el coste de recorrer 100 km y el tiempo para recorrer 100 km se encuentre dentro de una horquilla razonable y equitativa, en función del origen y destino de su desplazamiento.

Naturalmente, existirán excepciones como Madrid – Barcelona, que son las ciudades más grandes de España. Los tiempos de desplazamiento se encuentran en un límite inferior (tardará en recorrer 100 km menos que la media de la horquilla a plantear), aunque debido a los costes de los trenes de alta velocidad está por encima de la media de lo que cuesta recorrer 100 km. Conocidas las excepciones, lo que se necesita es determinar esos rangos de tiempos y costes para analizar los trayectos que se encuentran fuera de estos rangos. Estos trayectos serán los que estén fuera de un planteamiento lógico de movilidad futura, por lo que deberán de concentrarse los esfuerzos en mejorar esos tiempos y esos costes, si se pretende garantizar un servicio de transporte accesible, justo y equitativo para todos los ciudadanos.

Actualmente, no existen unos valores medios de costes y de tiempos para recorrer 100 km. Se trata de un área de trabajo para las líneas futuras, de tal manera que se puede ir trabajando en reducir cada vez más esa horquilla en todos los desplazamientos existentes en el país. De cara a realizar esta línea d trabajo futuro, en la metodología de esta tesis doctoral se proponen dos indicadores (Key Performance Indicator – KPI) fundamentales:

- **KPI 1:** costes incurridos en recorrer 100 km (€/100km).

- **KPI 2:** tiempo invertido en recorrer 100 km (h/100km).

A partir de los indicadores anteriores, es posible ir determinando los rangos existentes del 80 % de todos los desplazamientos de cada provincia, para cada uno de los tres medios de transporte mencionados (carretera, ferrocarril, avión). Una vez evaluados esos indicadores en cada desplazamiento, será sencillo analizar los valores límites superiores e inferiores y paralelamente fijar un objetivo como país de cara a los próximos 5 ó 10 años.

A partir de este análisis, saldrán a la luz los desplazamientos prioritarios a la hora de invertir en infraestructura y en servicios de transporte público. El estudio completo se puede encontrar en la referencia (Claessens Martínez, 2022), pero a modo ilustrativo se presentan a continuación una serie de ejemplos claros de movilidad bien planteada y de movilidad potencialmente mejorable.

En las tablas 4.7, 4.8 y 4.9, se muestra un ejemplo de los indicadores mencionados para 5 trayectos definidos, para distintos medios de transporte (coche, tren y avión).

Origen	Destino	distancia(km)	€/100 km	t/ 100 km
Madrid	Barcelona	620	8,965	1,03709677
Madrid	Valencia	358,8	8,965	1,05908584
Madrid	Sevilla	529,5	8,965	0,9694051
Madrid	Zaragoza	320,3	8,965	1,06668748
Madrid	Málaga	528,7	8,965	1,02137318

Tabla 4.7: Ejemplo de los indicadores planteados para el coche en 5 trayectos.

Origen	Destino	distancia(km)	€/100 km	t/100 km
Madrid	Barcelona	620	8,90322581	0,44354839
Madrid	Valencia	358,8	7,295	0,51086957
Madrid	Sevilla	529,5	7,47686497	0,48460812
Madrid	Zaragoza	320,3	7,74648767	0,42147986
Madrid	Málaga	528,7	7,97200681	0,52960091

Tabla 4.8: Ejemplo de los indicadores planteados para el tren en 5 trayectos.

Origen	Destino	distancia(km)	€/100 km	t/100 km
Madrid	Barcelona	620	9,83870968	0,21451613
Madrid	Valencia	358,8	21,1817168	0,2787068
Madrid	Sevilla	529,5	19,4523135	0,20453258
Madrid	Zaragoza	320,3	-	-
Madrid	Málaga	528,7	22,5080386	0,23642898

Tabla 4.9: Ejemplo de los indicadores planteados para el avión en 5 trayectos.

A continuación, se mostrarán dos de ejemplos en los que se obtienen conclusiones relevantes a partir de los indicadores definidos, y de acuerdo a la metodología planteada en este estudio:

- **Ejemplo 1: Madrid - Barcelona.** Se trata de las dos ciudades más importantes de España por lo que tienen conexión mediante tren de alta velocidad y también por avión, conocido como el puente aéreo de Barcelona.

Tiene sentido que, a nivel de costes, esté por encima de la media debido a que tiene la mejor conexión de alta velocidad. Y por otro lado, tiene sentido que esté en el límite inferior de lo que se tarda de media en recorrer 100 km. En este caso, se puede observar que el tren y el avión presentan costes similares, siendo algo inferior el del tren.

Con respecto a los tiempos, podría decirse que el avión tarda menos. Pero es cierto que no está contemplado los tiempos de desplazamiento de ambas ciudades al aeropuerto y por ello el tren de alta velocidad es un muy buen competidor del avión desde su aparición a principios de este siglo. En comparación con el coche, la ganancia máxima se encuentra en la reducción del tiempo de viaje, aunque a nivel de costes pueda ser parecido incluso un poco más económico el coche, en caso de ir más de un viajero. Poniendo tiempos y costes en la balanza, está claro que el transporte público presenta una muy buena oferta. Esta situación da lugar a que cualquier usuario se plantee primero recurrir a este transporte público, frente a su vehículo particular. Este debería ser el objetivo de todos los demás trayectos, esto es, garantizar que la mejor opción es el servicio de transporte público.

- **Ejemplo 2: Madrid - Sevilla.** En este ejemplo el tren de alta velocidad es claramente la mejor opción en materia de costes, dado que el avión es bastante más caro y el trayecto en coche sale menos económico que un billete estándar de tren. A nivel de tiempos, el avión sigue ganando al tren de alta velocidad, pero nuevamente sin contemplar los desplazamientos a los correspondientes aeropuertos. Por este motivo, la preferencia del usuario a nivel general se inclina por la opción del tren de alta velocidad. Como dato histórico, cabe destacar que fue la primera línea de alta velocidad que se abrió en España en abril del año 1992 (Shen et al., 2017). El coche está muy lejos de ser competidor en cuanto a los tiempos de viaje.

El segundo paso realizado en este apartado, es el análisis comparativo de los distintos medios de transporte en el 80 % de los trayectos que se estudian por cada provincia. De este modo, en los trayectos resultantes, es posible entender qué medio de transporte es más económico y qué medio de transporte es más rápido. Esta síntesis es esencial para detectar los trayectos que están más desatendidos en materia de tiempos y costes, según los criterios establecidos al principio de este apartado. La información presentada para el 80 % de los desplazamientos de cada provincia, es la siguiente:

- Porcentaje de desplazamientos.
- Medio de transporte más rápido.
- Tiempo que se tarda en realizar el trayecto de la forma más rápida posible.
- Medio de transporte más económico.
- Precio del medio de transporte más económico.
- Existencia de tren de alta velocidad (AVE) o no.

Con toda esta información, se podrá elaborar un orden prioritario de infraestructuras y trayectos en los que se deba invertir como país, para mejorar la movilidad global en su conjunto. A modo ilustrativo, se muestran a continuación algunos de los ejemplos más representativos, aunque puede encontrarse en el **Anexo 2** de este trabajo todas las tablas de cada una de las provincias. Se trata de los mismos ejemplos que se han mostrado antes: Madrid, Barcelona, Jaén, Cuenca, Toledo y Valencia.

Es interesante analizar la muestra completa dado que Madrid y Barcelona son las ciudades principales en España, y por tanto prioritarias en atención frente a otras provincias. Jaén es una provincia interior que se considera algo abandonada, dado que no existe potencial económico creciente o un alto interés cultural o turístico, por lo que no es una provincia prioritaria en materia de conexiones de transporte o inversiones en general por parte del estado.

Cuenca es una ciudad que se ha potenciado, porque se encuentra geográficamente en zona de paso de muchas conexiones importantes con la costa del levante, por lo que es una situación de buen trato en cuanto a conexiones ferroviarias, a pesar de ser una ciudad que tampoco es potencia prioritaria en materia económica o turística.

Toledo es un ejemplo de ciudad que tiene mucho flujo de movilidad desde la capital, y que posee unas conexiones excelentes en cuanto a transporte público se refiere.

Por último, Valencia representa una de las muchas ciudades costeras que tienen gran interés industrial, económico y turístico. Posee por tanto unas conexiones a la red de transportes muy decentes en materia ferroviaria.

En resumen, se ha escogido una muestra de 5 ciudades con distintas casuísticas para mencionar en este documento, aunque el estudio se ha realizado sobre todas las provincias existentes (Claessens Martínez, 2022).

Destino	Porcentajes	↓ tiempo	Tiempo (h)	↓ coste	Precio (€)	AVE
Toledo	41,76 %	tren	0,54	coche	6,5	SI
Guadalajara	22,99 %	coche	0,9	coche	6	SI
Ávila	3,89 %	coche	1,35	tren	9	NO
Segovia	3,5 %	tren	0,45	coche	8,2	SI
Ciudad Real	2,98 %	tren	0,9	tren	16	SI
Cuenca	2,29 %	tren	0,833	tren	14	SI
Valencia	1,75 %	avión	1	tren	19	SI
Alicante	1,41 %	avión	1	tren	21	SI

Tabla 4.10: Análisis comparativo de tiempos y costes entre distintos medios de transporte del 80 % de los desplazamientos producidos con origen en Madrid.

De la tabla 4.10 correspondiente a los trayectos producidos desde Madrid, se observa que un alto porcentaje de las personas que viajan desde esta ciudad lo hacen a Toledo y a Guadalajara. Estos destinos cuentan con un tren de alta velocidad. Sin embargo, en ninguno de los dos casos resulta ser la opción más barata, y además a Guadalajara tampoco es la opción más

rápida.

Se concluye que hay una buena conexión a Toledo mediante ferrocarril (es un tren AVANT, de velocidad alta). Es ligeramente más caro que el coche, aunque en tiempos gana considerablemente. En cuanto a Guadalajara, no se puede concluir que existe una buena conexión mediante transporte público en materia de tiempo y coste. En referencia al coste sí puede ser buena opción, pero escogiendo el cercanías como medio de transporte. Sin embargo, el tiempo se incrementa en un 50 % aproximadamente.

Con respecto al resto de los destinos, existe una casuística muy variada. Por ejemplo, a Ciudad Real o a Cuenca existe una buena conexión ferroviaria al ser el medio de transporte más rápido y el más económico. A Valencia y a Alicante, teniendo en cuenta los tiempos de desplazamiento a los aeropuertos y tiempos muertos de espera del transporte aéreo, también se considera que existe una muy buena conexión ferroviaria. Contemplando los porcentajes de los desplazamientos desde Madrid, las conexiones generales más importantes de solventar son las de Toledo y Guadalajara, y ambas están relativamente bien posicionadas en cuanto a tiempos y costes.

Destino	Porcentajes	↓ tiempo	Tiempo (h)	↓ coste	Precio (€)	AVE
Gerona	45,48 %	tren	0,6	coche	9,1	SI
Tarragona	28,94 %	tren	1,13	tren	10	SI
Lérida	9,74 %	tren	1	coche	14,2	NO

Tabla 4.11: Análisis comparativo de tiempos y costes entre distintos medios de transporte del 80 % de los desplazamientos producidos con origen en Barcelona.

En el caso de Barcelona, la población se desplaza mayormente a las provincias colindantes de Cataluña. En todas ellas existe tren de alta velocidad por lo que es la opción más rápida en los tres casos, aunque a Gerona y Lérida se debe estudiar un ligero ajuste de los precios de los billetes de tren, para garantizar de ese modo que el ferrocarril sea la opción preferida en tiempos y costes.

Destino	Porcentajes	↓ tiempo	Tiempo (h)	↓ coste	Precio (€)	AVE
Granada	31,7 %	coche	1	coche	8,4	NO
Córdoba	29,59 %	coche	1,4	coche	10,1	NO
Málaga	6,3 %	coche	2,25	coche	17	NO
Ciudad Real	5,15 %	coche	1,9	coche	15,5	NO
Madrid	5,11 %	coche	3,42	autobús	17	NO
Sevilla	4,9 %	coche	2,6	coche	22	NO

Tabla 4.12: Análisis comparativo de tiempos y costes entre distintos medios de transporte del 80 % de los desplazamientos producidos con origen en Jaén.

En cuanto a Jaén, es una provincia que no ha sido en los últimos años prioritaria en España como potencia económica, tal y como se ha mencionado anteriormente. La mayor parte de los

jienenses que viajan lo hacen a Granada o Córdoba. Sin embargo, el medio de transporte más económico y más rápido en ambos casos es el vehículo particular.

Esto significa que Jaén no posee una buena conexión de transporte público, de hecho, en algún caso es inexistente. Urge por tanto poner remedio a estas situaciones, y mejorar las conexiones ferroviarias con las provincias más visitadas por la población de Jaén en este caso. Esta información ha sido ya compartida con la alcaldía de Jaén, la cual trabaja intensamente en mejorar la situación.

Destino	Porcentajes	↓ tiempo	Tiempo (h)	↓ coste	Precio (€)	AVE
Madrid	18,7 %	tren	0,83	tren	14	SI
Valencia	13,33 %	tren	0,9	tren	8	SI
Toledo	12,69 %	coche	2,1	tren	19	SI
Ciudad Real	8,26 %	coche	2,67	coche	23,5	SI

Tabla 4.13: Análisis comparativo de tiempos y costes entre distintos medios de transporte del 80 % de los desplazamientos producidos con origen en Cuenca.

En cuanto a Cuenca, al ser una ciudad de paso entre las grandes ciudades, que además posee línea de alta velocidad, existen varias provincias colindantes a las que viaje la gente mayormente a diario. Las conexiones por vía ferroviaria con Albacete, Madrid y Valencia hacen que sea la opción más rápida y más económica, (pendiente de ajustar un poco el precio en el caso de Albacete). Sin embargo, a Toledo y Ciudad Real no existen buenas conexiones ferroviarias por lo que la opción más rápida es el coche. Esto debe revisarse para nuevamente garantizar que la mejor opción sea siempre el transporte público, y más concretamente, el transporte ferroviario.

Destino	Porcentajes	↓ tiempo	Tiempo (h)	↓ coste	Precio (€)	AVE
Alicante	35,82 %	tren	1,79	tren	13	NO
Castellón	32,49 %	tren	0,75	tren	6	SI
Albacete	4,59 %	tren	1,55	coche	19	NO
Cuenca	4,15 %	tren	0,9	tren	8	SI
Madrid	3,97 %	avión	1	tren	19	SI

Tabla 4.14: Análisis comparativo de tiempos y costes entre distintos medios de transporte del 80 % de los desplazamientos producidos con origen en Valencia.

La situación en Valencia es favorable al transporte ferroviario, dado que es la opción más rápida en todos los casos. Aunque parezca que a Madrid se tarda menos en avión, nuevamente considerando los tiempos de traslado al aeropuerto y de espera, sale aventajado el tren frente al avión. En cuanto al aspecto económico, también es la mejor opción exceptuando Albacete, que todavía debe realizarse algún pequeño ajuste para garantizar el transporte ferroviario como la mejor opción.

Destino	Porcentajes	↓ tiempo	Tiempo (h)	↓ coste	Precio (€)	AVE
Madrid	76,84 %	tren	0,54	coche	6,5	SI
Ciudad Real	8,06 %	coche	1,4	coche	10,5	SI

Tabla 4.15: Análisis comparativo de tiempos y costes entre distintos medios de transporte del 80 % de los desplazamientos producidos con origen en Toledo.

En el caso de Toledo prácticamente la mayor parte de los desplazamientos se realizan a la capital, es decir, a Madrid. Existe una conexión de alta velocidad entre Madrid y Toledo que garantiza que sea la opción más rápida en cualquier caso; aunque no es la opción más barata y se podría trabajar en ajustar el coste del billete, para que fuese también la opción preferida desde el punto de vista económico. Sin embargo, las personas que lo usan a diario poseen tarifas especiales que hacen que el coste no sea un problema, y por tanto sea la opción favorita para viajar desde Toledo a Madrid regularmente.

En cuanto a Ciudad Real, claramente no existe una buena conexión ferroviaria. La opción más rápida y barata resulta ser el vehículo particular, por lo que queda mucho trabajo por hacer en este trayecto para garantizar que la mejor opción sea la ofertada en transporte público, y más concretamente, en transporte ferroviario.

Como se ha podido comprobar en estos 5 ejemplos, con la información adjunta es posible sacar conclusiones sobre las infraestructuras y trayectos que merecen la pena reforzar de forma prioritaria, en función de la demanda de transporte solicitada por la sociedad. Esta información debe servir como variable de entrada indispensable, para la planificación futura de las inversiones en infraestructura de los distintos gobiernos, de cara a continuar trabajando en una movilidad inteligente. De este modo, se conseguirá ir adaptando al máximo posible la oferta y la demanda de transporte en función de las necesidades de la sociedad española. Cabe destacar que existen otra serie de variables que pueden modificar las prioridades, como la viabilidad económica o aspectos más subjetivos como la cultura social.

Un siguiente paso para continuar con este estudio que se propondrá en el capítulo de líneas futuras, es el análisis de la diferencia en precio y en tiempos con la segunda opción más rápida y barata, de tal manera que se tenga una percepción real de cuánto se debe mejorar cada uno de los trayectos, lo cual impactará directamente en la inversión de infraestructuras en la planificación del transporte futuro.

Con esta información particular de los ejemplos mostrados, se pone fin a este segundo apartado, que pretende mostrar la oferta existente de los servicios de transporte accesibles para la población española.

Esta información es muy valiosa de cara a ser cruzada con el estudio realizado en el apartado anterior. Teniendo la demanda de transporte clara y conociendo la oferta de medios de transporte, se puede determinar el equilibrio existente en su combinación. De este modo, en el siguiente apartado, se demuestra la eficiencia de la inteligencia artificial de cara a encajar la oferta y la demanda de transporte, alcanzando los máximos niveles posible de optimización de recursos.

4.3 Optimización de la movilidad para adaptar oferta y demanda

En este tercer apartado, el más relevante de esta tesis doctoral, se pretende demostrar la efectividad y las ventajas de emplear la inteligencia artificial, tanto en la predicción de la movilidad de las personas, como en la optimización de la operación y el mantenimiento del transporte ferroviario, desde los distintos grupos de interés que intervienen. Nuevamente, se concentra la aplicación en el sector de la movilidad ferroviaria de viajeros, pero es igualmente extrapolable a la movilidad de mercancías a partir de la información de entrada adecuada, o a la movilidad cubierta por cualquier otro medio de transporte.

Se van a presentar 5 casos de éxito, que a su vez se han publicado o están en vías de ser publicados en revistas de prestigio Q1, Q2 ó Q3 del sector.

El primero de todos, tal y como se ha comentado ya, se concentra en el uso de modelos de redes neuronales para predecir los desplazamientos existentes entre dos puntos determinados. Los demás casos, se centran en la optimización del mantenimiento, entrando en el ámbito concreto del mantenimiento predictivo.

Como se ha justificado al comienzo de este apartado, el mantenimiento es fundamental para una operación segura y fiable, y que cumpla con los requisitos ya expuestos en el apartado 2.1.2 de esta tesis en cuanto al concepto RAMS.

La disponibilidad se vuelve cada vez más importante, y se debe encontrar un equilibrio entre la velocidad máxima de operación, la capacidad de las líneas ferroviarias, y el mantenimiento tanto del material rodante como de las infraestructuras. A mayor velocidad de circulación, mayores operaciones de mantenimiento asociadas y por tanto menos disponibilidad de la infraestructura o del material rodante. En este contexto, una labor fundamental del sector es tratar de minimizar los mantenimientos preventivos, e ir transformándolos en predictivos, con objeto de maximizar la disponibilidad y la operación ferroviaria, y minimizar los costes económicos y energéticos asociados.

Dentro de los múltiples componentes existentes en un tren, se debe trabajar de forma prioritaria en aquellos que tienen una influencia directa en seguridad, disponibilidad y fiabilidad. Se debe garantizar un buen análisis RAMS, acorde con un control de calidad adecuado y unas condiciones de seguridad garantizadas y supervisadas de forma periódica. Se estudian, por tanto, 4 casos relacionados con el mantenimiento predictivo.

El primer caso se centra en una infraestructura ferroviaria, en concreto en la predicción de condiciones degradadas debido a lluvias torrenciales en un puente. El objetivo es poder adoptar con antelación las restricciones de velocidad y de operación bajo estas condiciones climatológicas, garantizando siempre la seguridad, pero evitando la cancelación de circulaciones por desconocimiento del estado del puente. De este modo se puede analizar con antelación cuál es la maximización de la operación de los trenes en estas condiciones tomando medidas como LTV, cancelaciones parciales durante un periodo de tiempo de las circulaciones, ...

Los otros tres casos, se centran en el mantenimiento predictivo de componentes de seguridad del tren, que principalmente se centran en la rodadura (temperatura de rodamientos) y en

la estructura (aceleraciones transversales de la caja). Ambas variables se consideran de alta seguridad para la operación del tren, y están supervisadas en tiempo real de forma constante con sensores redundantes para poder contrastar ambas fuentes de información. Además, estas dos señales se exigen desde el punto de vista normativo, y se determinan límites máximos a partir de los cuales se deben aplicar restricciones en la operación del propio tren por motivos de seguridad. En el caso de estudio de las aceleraciones, no solo se trata el tema predictivo con objeto de garantizar la fiabilidad, disponibilidad y seguridad, sino que se da un paso adicional en el estado del arte, y se propone un concepto relacionado con la experiencia de usuario. Más concretamente, se determinan modelos capaces de detectar la degradación del confort del viajero durante la marcha, detectando una pérdida de calidad con alta precisión, sin tener que alcanzar los niveles de seguridad establecidos por la normativa vigente.

Por tanto, con los datos ya existentes en los trenes con objeto de garantizar el concepto de RAMS mencionado, puede adicionalmente emplearse la inteligencia artificial para extraer modelos que consigan aplicaciones adicionales que aporten un valor añadido a la movilidad ferroviaria en su conjunto, en este caso con una aplicación de afectación directa al usuario final.

A continuación, se especifican de forma concreta los 5 casos de éxito mencionados:

- **Caso 1. Predicción de la movilidad de viajeros en España empleando redes neuronales.** Se escogen unas rutas concretas y a partir de los datos recopilados por el MITMA, se aplican algoritmos de redes neuronales para predecir a futuro los desplazamientos de las personas, obteniendo resultados muy precisos en las rutas más frecuentadas. Se logra obtener una información esencial para acercar la oferta y la demanda, y por tanto para alcanzar una clara optimización de la movilidad. Este artículo científico se muestra actualmente en revisión (peer review, Garrido Martínez - Llop, [2023a](#)).
- **Caso 2. Predicción de comportamiento dinámico anómalo de un puente ferroviario con el paso de los trenes, debido a condiciones climatológicas extremas.** En este artículo científico se emplea la inteligencia artificial para predecir la respuesta dinámica de un puente ferroviario con el paso de los trenes en condiciones normales, de tal forma que pueda detectarse un comportamiento anómalo del mismo debido a condiciones climatológicas extremas como las fuertes lluvias, dando lugar a restricciones en la operación para garantizar los máximos niveles de seguridad. Se logra optimizar la operación ferroviaria debido a la detección temprana de un comportamiento anómalo de la infraestructura, evitando incurrir en riesgos de la operación, y dando lugar a poder mitigar con suficiente antelación el riesgo detectado. Es un claro ejemplo de optimización del mantenimiento de infraestructura ferroviaria. Este artículo científico se muestra actualmente en revisión (peer review, Garrido Martínez - Llop, [2023b](#)).
- **Caso 3. Predicción de fallos de rodamientos ferroviarios por sobre temperatura.** En este artículo científico se construyen diversos modelos de inteligencia artificial basados en redes neuronales, con objeto de predecir el fallo de un rodamiento ferroviario por altas temperaturas. Los rodamientos ferroviarios son un elemento de seguridad, y por tanto se debe monitorizar de forma redundante las temperaturas que alcanzan durante

la operación. En caso de detectar sobre temperaturas, debe limitarse la velocidad de circulación, e incluso detener el propio tren con las consecuencias que ello conlleva. La predicción de esta clase de fallos ayuda a optimizar la operación, y se enmarca en el contexto de mantenimiento predictivo del material rodante, evitando así cualquier incidente durante la operación. Este artículo científico ha sido publicado recientemente en una revista científica Q3 (Martínez-Llop et al., 2022).

- **Caso 4. Predicción de la degradación del confort del viajero por deterioro de la amortiguación del tren.** Las aceleraciones son otras variables que se recogen de forma redundante en los trenes, de cara a garantizar la seguridad de la operación. En este artículo se crea un modelo de redes neuronales, para poder predecir un comportamiento anómalo de las aceleraciones de la estructura de un tren de alta velocidad. Dado que el modelo se entrena con muchos trayectos de comportamiento normal de las aceleraciones, al existir un comportamiento anómalo o que se aleja de lo habitual se detecta con el algoritmo. Con esta información, se promueve la inspección de la suspensión y la amortiguación del vehículo en cuestión. En este artículo se logra por tanto detectar el momento en el que comienza una pérdida de confort en el tren, porque las aceleraciones de la estructura del tren pasan a comportarse de manera distinta a la habitual. Este artículo científico se ha publicado en una revista científica Q2 recientemente (Martínez-Llop et al., 2021).
- **Caso 5. Predicción de la degradación del confort del viajero por deterioro de la amortiguación del tren, empleando redes *LSTM*.** Este artículo científico es muy similar al anterior, pero la diferencia es que trabaja con algoritmos más complejos del tipo *LSTM* (*long short – term memory*). La idea principal de este estudio es determinar si el empleo de algoritmos más complejos, y que además puedan tener en cuenta de alguna forma la variable temporal, ofrecen una ventaja clara en comparación al mayor coste de computación, o realmente no merece la pena complicar el modelo. Se debe encontrar el balance entre la complejidad del algoritmo (y el coste de cálculo asociado) para conseguir el objetivo de la aplicación concreta. Este artículo se ha publicado en una revista científica Q1 (Martínez-Llop et al., 2023).

4.3.1 Caso 1. Predicción de la movilidad de viajeros en España empleando redes neuronales.

Objetivo

En este estudio se presenta un modelo predictivo para la movilidad en España de cuatro rutas representativas que son:

- Madrid – Barcelona (M – B).
- Madrid – Jaén (M – J).
- Cuenca – Valencia (C – V).
- Madrid – Toledo (M – T).

Aplicando una de las técnicas más importantes del aprendizaje automático dentro del *machine*

learning, las denominadas redes neuronales, el algoritmo es entrenado para predecir la movilidad a futuro en estos cuatro trayectos. El modelo se ha entrenado a partir de los datos obtenidos por el MITMA, y que ya se han presentado en este trabajo.

En primer lugar, se trabaja en optimizar una de las rutas de manera aislada a partir de los desplazamientos dados, y posteriormente se trata de crear un único modelo para cualquier ruta analizando los errores obtenidos. De este modo, se puede verificar la bondad del empleo de un modelo para cada ruta frente a crear un modelo generalizado. Se trata de analizar si el error obtenido en este segundo caso es admisible, ya que computacionalmente el coste es bastante menor si se tiene un solo algoritmo para dicho fin, en vez de uno particular para cada ruta.

Base teórica

En esta sección, se exponen brevemente las bases teóricas del algoritmo empleado en este artículo científico, con objeto de caracterizar la parte técnica empleada para la resolución del problema. Se han empleado redes neuronales artificiales (*ANN*), que son un conjunto de algoritmos incluidos en el campo de *machine learning*, diseñados para que los ordenadores puedan aprender y procesar unos datos introducidos previamente, simulando los principios básicos de funcionamiento de un cerebro humano.

Más concretamente, estas redes neuronales se engloban dentro del aprendizaje supervisado, y a partir de los datos de entrada contenidos en el vector $\mathbf{x}$, se genera una salida $\mathbf{y}$ tras ser procesada por una función que posee una parte lineal y una parte no lineal. Dado que la información introducida al modelo es conocida de antemano, una vez realizadas las predicciones, el propio modelo puede compararlo con los resultados reales, y así calcular el error para tratar de reducirlo ajustando los parámetros e hiperparámetros de la red neuronal (“Coursera | Online courses credentials from top educators. Join for free | Coursera”, [s.f.](#)).

Existen dos grandes tipos de problemas a resolver mediante el aprendizaje supervisado, y más concretamente, empleando las redes neuronales. Son los problemas de clasificación o regresión, siendo de regresión el que nos ocupa en este caso concreto. Se pueden configurar infinidad de redes neuronales variando su estructura, el número de capas, el número de nodos, las conexiones entre las distintas capas, las funciones no lineales, los hiperparámetros, ... Su configuración, denominada arquitectura, se terminará dependiendo de la naturaleza del problema, del conjunto de datos a emplear, etc.

La estructura de una red neuronal viene dada por una serie de unidades denominados nodos o neuronas, que están interconectados entre sí para formar una red. A partir de los datos de entrada, se procesa la información en una función lineal y posteriormente en una función no lineal, obteniendo una variable de salida que será a su vez entrada de la siguiente capa de la estructura formada. En la figura 4.13 se puede encontrar la arquitectura de una red neuronal artificial (“Artificial neural networks”, [s.f.](#)).




Figura 4.13: Estructura de una red neuronal artificial (ANN).




Figura 4.14: Estructura de una neurona.

Una red neuronal está organizada en distintas capas. La primera capa se corresponde a la capa de entrada en la que se introducen las variables de entrada del modelo. Una vez procesados los datos en la primera capa, va pasando por sucesivas capas denominadas capas ocultas. En cada capa hay una serie de neuronas tal y como puede contemplarse en la figura 4.13. Finalmente, la última capa contiene una sola neurona, y la salida de esta capa da lugar a la salida del modelo completo.

Existe una notación concreta para distinguir las distintas capas, neuronas y las operaciones

que se realizan en cada una de ellas. En la figura 4.14 se muestra la estructura de una neurona, diferenciándose la parte lineal de la parte no lineal en cuanto a las operaciones se refiere.

Cada neurona admite un vector de entrada denominado $\mathbf{x}$ el cual sufre primero una operación lineal y posteriormente una operación no lineal, a través de la función de activación (Parhi y Nowak, 2020) representado por 4.2:

$$z_j = \mathbf{w}_j^{[i]t} \mathbf{x} + b. \quad (4.1)$$

$$a_j^{[i]} = \sigma(z_j^{[i]}). \quad (4.2)$$

La función $\mathbf{z}$ representa la operación lineal, siendo $\mathbf{w}$ la matriz de pesos y b el término del bias o sesgo. No se entrará en este texto en mucho más detalle técnico y matemático del algoritmo, por no ser el objetivo principal de este documento.

En cuanto al funcionamiento de la red neuronal, en primer lugar, se establecen de forma aleatoria los pesos ($\mathbf{w}$) y se lleva a cabo una secuencia de cuatro pasos diferenciados: propagación hacia adelante, realizando todos los cálculos en cada una de las capas y neuronas; evaluación de la función de coste, que compara los resultados obtenidos con los reales; propagación hacia atrás (trabajando con derivadas parciales); y ajuste nuevamente de los parámetros para poder comenzar de nuevo con la secuencia. Estos pasos se repiten una y otra vez hasta que la evaluación de la función de coste se reduce hasta niveles aceptables, logrando obtener unas predicciones adecuadas para el fin esperado (Aggarwal, 2018).

La función de coste viene dada por la siguiente ecuación (4.3):

$$J(\mathbf{w}, b) = \frac{1}{m} \sum_{i=1}^n L(\hat{\mathbf{y}}, \mathbf{y}) \quad (4.3)$$

El objetivo primordial del proceso iterativo es minimizar esta función de coste, en la que m representa el número de muestras entrenadas, $\mathbf{y}$ el vector de datos reales, $\hat{\mathbf{y}}$ las predicciones realizadas, y L la función de coste que se ha considerado (puesto que existen diversas funciones de coste).

Una vez evaluado el error cometido a través de la función de coste, se continúa con la propagación hacia atrás, en la que también existen diversos modelos matemáticos como el del descenso del gradiente o el optimizador Adam (Kingma y Ba, 2014).

Este paso permite volver a actualizar los pesos iniciales para comenzar de nuevo con el proceso iterativo, e ir obteniendo cada vez un error más reducido hasta alcanzar los valores deseados.

Para ajustar el modelo y alcanzar mejores resultados existen una serie de hiperparámetros que pueden ajustarse, pero no entraremos en más detalle técnico por no ser el núcleo fundamental de esta tesis doctoral. Para cada uno de los algoritmos empleados en esta tesis doctoral se determinarán los valores asignados a cada hiperparámetro del modelo.

Existen diversos tipos de error para calcular el rendimiento de la red neuronal creada. Los más comunes se presentan a continuación:

- **RMSE:** *root-mean-square error* (error cuadrático medio), que determina la suma total de las diferencias entre los valores predichos por el modelo y los valores reales al cuadrado.
- **MAPE:** *mean absolute percentage error* (error porcentual absoluto medio), que mide la dimensión del error en términos porcentuales.

Por último, conviene destacar que para resolver los problemas mediante redes neuronales, se crean 3 conjuntos de datos distintos a partir de los datos iniciales: el conjunto de entrenamiento, que sirve para entrenar el modelo; el conjunto de validación, que se usa para poder evaluar el modelo mientras se ajustan los hiperparámetros de una forma no sesgada; y por último, el conjunto de test, para hacer una evaluación imparcial del modelo final entrenado.

Las mejores prácticas normalmente recomiendan que se use un 80 % de los datos disponibles para la fase de entrenamiento, un 10 % para la validación y otro 10 % para el test (Foody et al., 1995) que existen otros repartos habituales que suelen emplearse.

Modelos y resultados

Se han empleado los mismos datos descritos en el primer apartado de este capítulo, es decir, los datos de movilidad del MITMA tomados desde julio de 2020 hasta abril de 2021. Se seleccionan de las matrices correspondientes a los municipios (*Maestra 1 – Municipios*) las 4 rutas mencionadas: Madrid – Barcelona, Madrid – Jaén, Cuenca – Valencia, Madrid – Toledo. Siguiendo todas las recomendaciones técnicas para el empleo de las redes neuronales tal y como se ha mencionado arriba, se crean los distintos modelos de redes neuronales para la predicción de los desplazamientos en estas rutas. Existen en estas rutas un total de 28 741 desplazamientos aproximadamente (muestras para el modelo), que contienen todas las variables de entrada explicadas al principio de este apartado.

Como en todo problema de inteligencia artificial se debe primeramente limpiar y filtrar los datos. Se eliminan los datos erróneos o muestras incompletas, y se asegura la fiabilidad y robustez de las muestras. La precisión del modelo en cuestión depende en gran parte de la robustez y fiabilidad de los datos de partida. Por ello se dice que es la fase más importante de todo el proceso, el de la preparación y limpieza de los datos.

Se comienza desarrollando una red neuronal de arquitectura sencilla para predecir los viajes de Madrid a Barcelona, es decir, un modelo particularizado solo para este trayecto. Las arquitecturas de los modelos que mejor han funcionado para la predicción de la movilidad Madrid – Barcelona son las siguientes:

- **Red neuronal con una capa oculta:**
 - Architecture: [800, 1].
 - Activation function: ReLU.
 - Dropout: Yes.
 - Optimizer: Adam.
 - Variable Learning Rate: Yes.

- Loss function: Mean Square Error
- Number of epochs: 2 000.
- Callbacks: Early Stopping.
- Batch size: 16.
- **Red neuronal con dos capas ocultas:**
 - Architecture: [400, 40, 1].
 - Activation function: Softplus.
 - Dropout: Yes.
 - Optimizer: Adam.
 - Variable Learning Rate: Yes.
 - Loss function: Mean Square Error.
 - Number of epochs: 2 000.
 - Callbacks: Early Stopping; model checkpoint.
 - Batch size: 50.
- **Red neuronal con tres capas ocultas:**
 - Architecture: [400, 40, 40, 1].
 - Activation function: ReLU.
 - Dropout: Yes.
 - Optimizer: Adam.
 - Variable Learning Rate: Yes.
 - Loss function: Mean Square Error.
 - Number of epochs: 2 000.
 - Callbacks: Early Stopping; model checkpoint.
 - Batch size: 50.

En la tabla 4.16 se muestra el rendimiento de los tres modelos expuestos, teniendo en cuenta que además de los errores ya presentados. Se muestra también la media del test y de la predicción, y el R^2 como indicadores adicionales del funcionamiento de la red neuronal. El R^2 es bien conocido en estadística, y cuanto más se acerca a 1 significa que más se parecen las predicciones a los valores reales (en un ámbito de linealidad). Salen valores altos de R^2 en todos los casos. En cuanto a la media del test y de las predicciones, de igual forma cuanto más parecidos sean esos valores mejor rendimiento presenta el modelo.

Model	Test Mean	Prediction Mean	RMSE	MAPE [%]	R^2
[800, 1]	193,556	194,576	28,084	9.125	0.968
[400, 40, 1]	193,556	193,335	27,758	7.907	0.969
[400, 40, 40, 1]	193,556	192,611	28,121	7.93	0.968

Tabla 4.16: Rendimiento de los tres modelos de redes neuronales propuestos para el modelo predictivo de la ruta Madrid – Barcelona.

A partir de los resultados anteriores, se observa que el modelo que mejor funciona es el modelo dos, presentando un MAPE de 7,91 %, lo cual es un valor bastante aceptable, aunque se recomienda por criterio experto estar cerca del 5 %.




Figura 4.15: Ajuste de las predicciones frente a una regresión lineal.

Este modelo optimizado se prueba para las demás rutas propuestas obteniéndose los resultados mostrados en la tabla 4.17, probándose con los datos correspondientes a los dos sentidos. 2

Route	Test Mean	Prediction Mean	RMSE	MAPE [%]	R^2
M-B	193,556	193,335	27,758	7.907	0.969
B-M	192,741	192,995	27,750	9.407	0.969
M-J	127,679	126,994	22,254	11.355	0.957
J-M	193,556	131,304	33,549	11.617	0.919
C-V	334,100	336,575	47,749	9.539	0.968
V-C	349,318	350,499	41,650	8.018	0.976
M-T	6,259,830	6,242,895	485,594	5.379	0.995
T-M	6,329,545	6,335,863	481,187	5.93	0.989

Tabla 4.17: Rendimiento del modelo óptimo para las rutas propuestas en los dos sentidos.

A la vista de los resultados, en todas las demás rutas y trayectos, salvo el de Madrid – Toledo en ambos sentidos, el rendimiento es peor. Esto era de esperar puesto que se ha entrenado el modelo con los datos de la ruta Madrid – Barcelona. Sin embargo, el trayecto Madrid – Toledo y Toledo – Madrid presenta unos resultados mucho mejores. Esto tiene una explicación muy sencilla: Esta ruta presenta un volumen de personas desplazadas mucho mayor, con menor variabilidad, por lo que la predicción es más fácil para un modelo que ha sido entrenado en una ruta con menor complejidad, desde este punto de vista.

En último lugar, se juntan todos los datos de las 4 rutas comentadas, y se entrena un modelo que pretender ser generalizado para cualquier ruta entre provincias en cualquier sentido. Cabe esperar peores resultados que el particularizado para Madrid – Barcelona o Madrid – Toledo. Pero resulta interesante conocer si con un solo modelo optimizado se alcanzan unos resultados que pueden darse por válidos, a efectos de la predicción de movilidad que pretende realizarse.

Se presentan a continuación las arquitecturas de los dos modelos que mejor rendimiento han alcanzado tras la fase de entrenamiento de la red neuronal:

- **Red neuronal con dos capas ocultas:**

- Architecture: [800, 400, 1].
- Activation function: Softplus.
- Dropout: Yes.
- Optimizer: Adam.
- Variable Learning Rate: Yes.
- Loss function: Mean Square Error.
- Number of epochs: 2 000.
- Callbacks: Early Stopping; model checkpoint.
- Batch size: 50.

- **Red neuronal con tres capas ocultas:**

- Architecture: [400, 200, 18, 1].

- Activation function: Softplus.
- Dropout: Yes.
- Optimizer: Adam.
- Variable Learning Rate: Yes.
- Loss function: Mean Square Error.
- Number of epochs: 2 000.
- Callbacks: Early Stopping; model checkpoint.
- Batch size: 32.

En la tabla 4.18 se muestran los resultados de estas dos redes neuronales entrenadas con todos los datos de los trayectos mezclados, con objeto de obtener un modelo único de predicción de movilidad entre provincias en España.

Model	Test Mean	Prediction Mean	RMSE	MAPE [%]	R^2
[800 400 1]	1 793 520	1 795 339	120,124	16,43	0.998
[400 200 18 1]	1 793 520	1 790 114	119,817	13.427	0.998

Tabla 4.18: Rendimiento de los dos modelos óptimos entrenados con todos los datos de las 4 rutas previstas.

Tal y como se ha mencionado anteriormente, con una mayor cantidad de datos será posible ajustar más los parámetros del modelo y obtener mejores resultados. No solamente el volumen de datos de entrada del algoritmo influye, sino también el ajuste de los distintos hiperparámetros de los modelos

Por otro lado, es importante destacar que para cada problema resuelto, se deben definir las tasas de éxito en cuanto a los valores obtenidos de MAPE o RSME. Es decir, dependiendo de la naturaleza del problema escogido, se considerarán unos u otros valores como resultado exitoso del algoritmo.

En este caso, en el que se trabaja con los desplazamientos de millones de personas, un error del entorno del 10 % se considera exitoso, ya que se trata de obtener aproximaciones suficientemente precisas como para poder planificar medios de transporte masivos. Por este motivo, afinar hasta un número de 5 ó 10 viajeros no tendría ningún sentido para el propósito mencionado.

El hecho de comparar un modelo común para cualquier trayecto, frente a uno particularizado para una ruta concreta, es interesante de cara a conocer si el modelo global es suficientemente preciso para el objetivo buscado. El motivo que subyace es el poder emplear un modelo general y no tener que invertir altos costes computacionales, por el ajuste de todos los modelos uno a uno que surgen de cada trayecto particular.

A modo ilustrativo se muestra en la figura 4.16 el ajuste de las predicciones frente a los valores reales.




Figura 4.16: Ajuste de las predicciones frente a una regresión lineal.

A partir de los resultados anteriores, somos capaces de obtener un modelo de predicción de movilidad general para cualquier trayecto entre provincias con un MAPE de 13.47 %. Este resultado se considera satisfactorio para el fin previsto, pero se considera que entrenando el modelo con más datos y más actualizados (que ya existe la posibilidad), podrán obtenerse todavía mejores resultados.

Conclusiones

Como conclusión general de este caso de estudio, las redes neuronales funcionan de manera satisfactoria de cara a obtener modelos de predicción de la movilidad entre provincias. Cuanto mayor es la base de datos disponible, mejores predicciones se obtienen tras entrenar el modelo. Se puede entrenar una red neuronal para cada una de las rutas y en cada sentido. En el mejor de los casos se ha obtenido un MAPE del 5,38 %. Entrenando un modelo general para cualquier trayecto en cualquier sentido entre provincias, se obtiene un MAPE de 13,47 %, lo cual es aceptable para el propósito de predecir la movilidad entre provincias. Este resultado puede ser mejorable con una mayor cantidad de datos y con un trabajo más profundo en los modelos planteados, por lo que se invita a darle continuidad en las líneas futuras del presente estudio.

4.3.2 Caso 2. Predicción de comportamiento dinámico anómalo de un puente ferroviario con el paso de los trenes debido a condiciones climatológicas extremas.

Objetivo

El objetivo de este caso es proponer una metodología para definir el número óptimo de transductores necesarios y sus valores límite, de acuerdo con los administradores de infraestructuras, con objeto de monitorizar el comportamiento de un puente y tomar decisiones relativas a la seguridad de la circulación por dicho puente, de la antigua línea ferroviaria Madrid – Cádiz.

La novedad de este trabajo es encontrar una aplicación real de la inteligencia artificial (técnicas de aprendizaje automático), en la monitorización de las infraestructuras ferroviarias para optimizar su mantenimiento, detectar la presencia de condiciones degradadas, y proporcionar herramientas para que los administradores de infraestructuras tomen decisiones en tiempo real.

Base teórica

En este artículo científico se emplean dos algoritmos de inteligencia artificial principales: El *Random Forest*, para la caracterización de la relación entre las distintas variables medidas en el puente y determinación de las más críticas que deben ser monitorizadas; y las redes neuronales recurrentes (*RNN – LSTM*) para la predicción de las aceleraciones obtenidas en los puntos críticos del puente, identificados por el Random Forest (Hengl et al., 2018).

A partir del algoritmo de *Random Forest* se intenta predecir las aceleraciones, del punto o los puntos más críticos que sean capaces de caracterizar el comportamiento dinámico normal del puente. Para ello, conocidos los datos de partida, se elimina la columna del sensor en cuestión y se realiza la predicción de tal manera que, luego se compara con los datos reales para comprobar el rendimiento del modelo. Estas aceleraciones se predicen en función de todas las demás variables que se miden.

Se escoge el algoritmo de *Random Forest* debido a la no linealidad del problema, de lo contrario se hubiera escogido una regresión lineal para tal fin. En el estado del arte se comprueba el buen funcionamiento de los árboles de decisión, cuando se plantean problemas en los que la no linealidad está presente.

Este algoritmo es uno de los más precisos y empleados en el aprendizaje automático supervisado, ya sea para problemas de regresión o problemas de clasificación. Emplea una distribución aleatoria de un número predeterminado de árboles de decisión, y considera como valor final de predicción la media de todos los resultados obtenidos en cada uno de los árboles de decisión. Se trata de un algoritmo de aprendizaje conjunto. Al igual que sucedía con las redes neuronales, existen una serie de hiperparámetros que ayudan a determinar el número de árboles de decisión, si se tienen todos los valores en cuenta o no, etc.

En la figura 4.17 se representa un diagrama simplificado de un modelo de Random Forest.




Figura 4.17: Diagrama simplificado de un modelo de Random Forest.

El funcionamiento de un árbol de decisión con p variables de entrada se presenta a continuación:

- El espacio p - dimensional de la característica en cuestión, se divide en M regiones distintas que cubren por completo el subconjunto de la característica, y sin que haya solapes.
- El rango de valores de cada variable se divide en dos partes (nodos). Se selecciona la partición que minimiza el error total y el proceso continúa creando nuevos nodos. Este algoritmo iterativo termina cuando se determina un error aceptable. La función que se utiliza para medir la calidad de una partición suele ser la función de “impureza de Gini”, que mide la frecuencia con la que se clasifica incorrectamente un atributo elegido al azar.
- Para el proceso de predicción, se empuja un nuevo caso hacia abajo en el árbol y se le asigna la etiqueta o el número del nodo final (J. Chen et al., 2019).

El algoritmo de *Random Forest* presenta menos errores de generalización y una mayor precisión, por lo que lo hace apropiado en problemas en los que se desconocen los datos de partida, o la relación entre las variables que intervienen en el problema (Breiman, 2001).

Una vez el algoritmo de *Random Forest* está ajustado, otro algoritmo denominado *SHAP* (*SHapley Additive exPlanations*) basado en la teoría de juegos, determinará la influencia de cada uno de los transductores o sensores en la predicción final del modelo. El objetivo es poder detectar si existen acelerómetros, o sensores redundantes, o que no estén aportando información relevante para las predicciones del comportamiento dinámico del puente, y por

tanto, se pueda prescindir de ellos. Como resultado de esta fase se obtienen los puntos relevantes para determinar el comportamiento dinámico normal del puente. Estos puntos son considerados de seguridad, y se elaborará una red neuronal recurrente de forma separada, para predecir los valores de aceleración en dichos puntos.

El otro algoritmo de inteligencia artificial empleado es el de las redes neuronales recurrentes, un caso específico de *deep learning*. Al igual que sucedía con las redes neuronales artificiales, su rendimiento es muy alto para cierta clase de problemas de clasificación o de regresión, en los que existen relaciones no lineales. En el apartado anterior se han presentado las redes neuronales artificiales, por lo que en este apartado se comentarán las diferencias que existen entre las redes neuronales artificiales y las recurrentes.

En este caso de estudio, se decide usar las redes neuronales recurrentes, dado que el tiempo juega un papel fundamental al intentar caracterizar el comportamiento dinámico del puente, es decir, una variable física que depende realmente de la variable temporal.

Las redes neuronales recurrentes son capaces de trabajar con las predicciones del instante anterior. Dicho de otro modo, la predicción en el tiempo t de una red neuronal recurrente, considera también como variable de entrada la predicción realizada en el tiempo $t-1$. Este aspecto es fundamental para sistemas dinámicos en los que los desplazamientos, las aceleraciones y las velocidades están relacionadas entre sí no solo numéricamente, sino que están relacionadas a nivel temporal por motivos de la física. Lo que ocurre en el instante anterior afecta al comportamiento dinámico del instante siguiente.

Sin embargo, presentan también algún que otro inconveniente matemático con los gradientes, lo que puede impedir que la red deje de aprender en el proceso de propagación hacia atrás. No se entrará en detalle técnico en este apartado. Debido a estos inconvenientes se decide finalmente trabajar con las redes *LSTM*, (*long-short term memory*; Hochreiter y Schmidhuber, 1997). Esta arquitectura introduce una serie de puertas, para determinar la información que ha sido retenida por la red neuronal, y la que ha sido olvidada en cada una de las iteraciones. De este modo, con simples operaciones algebraicas se corrige el problema detectado con los gradientes.

El funcionamiento de la red neuronal recurrente como proceso iterativo, es equivalente al de la red neuronal artificial ya explicado. En este caso, el modelo representa una estructura física a través de una serie de variables dinámicas, que dependen de ciertas características físicas como la masa, la amortiguación o la rigidez. Todas ellas caracterizan el comportamiento dinámico del puente o de la estructura. Una vez caracterizado el buen comportamiento (o comportamiento normal) de la estructura, los valores con alta tasa de error atípicos y predichos por el modelo, pueden significar lo siguiente:

- Degradación prematura de la estructura, expresada a través del cambio en la rigidez del material.
- Presencia de algún desastre natural puntual como pueda ser un terremoto o lluvias torrenciales, que generen un cambio en la amortiguación de la estructura.
- Cambio en la masa por ejemplo debido a la presencia de agua por inundaciones.

Realmente las redes neuronales son una caja negra. Esto significa que, ante las mismas variables de entrada, debe obtenerse la misma salida o respuesta. Si las predicciones empiezan a alejarse de lo esperado, es un indicativo de que el comportamiento de la infraestructura no es el habitual en condiciones normales, y por tanto puede existir alguna condición degradada que ponga en riesgo la circulación de los trenes en este caso.

Metodología seguida

La metodología consta de tres fases. La primera fase, basada en un algoritmo de *Random Forest*, predice la respuesta en los estribos del puente cuando un tren pasa a través de éste.

Mediante un estudio de significación estadística, se obtienen los puntos clave en términos de definir el estado de salud del puente. Las variables clave a monitorizar que resultan del estudio, son las aceleraciones del estribo del puente (sensor S1 en el ensayo realizado), y se demuestra que se obtiene información relevante del sensor central ubicado en el centro del vano del puente. La longitud total del puente no afecta al modelo, pero la longitud del vano es un parámetro importante a tener en cuenta.

La segunda fase consiste en la implementación de un conjunto de redes neuronales *LSTM* (*long short – term memory*), que predicen la respuesta en cada punto crítico detectado, que caracteriza un comportamiento dinámico del puente en condiciones normales (sin lluvia, acumulación de agua u otras condiciones ambientales o climáticas extremas).

Finalmente, en la fase 3 se implementa la inteligencia artificial, empezando por el entrenamiento del algoritmo y la definición de los valores límite de error que podrán imponer alguna restricción de circulación. La metodología evalúa los datos en tiempo real y con las condiciones reales de circulación.

Después de la optimización del modelo, con objeto de verificar la fiabilidad de este, se introducen a las redes neuronales recurrentes, entrenadas con datos de 3 casos de lluvias fuertes o acumulación de agua. Los errores obtenidos, son de 7 a 8 veces mayores que los obtenidos con el modelo entrenado con datos correspondientes a buenas condiciones climáticas.

Después de la optimización del modelo, con objeto de verificar la fiabilidad de éste, se introducen a las redes neuronales recurrentes, entrenadas con datos de 3 casos de lluvias fuertes o acumulación de agua. Los errores obtenidos, son de 7 a 8 veces mayores que los obtenidos con el modelo entrenado con datos correspondientes a buenas condiciones climáticas.

A continuación, se profundizará más sobre el desarrollo y la metodología empleada para conseguir el objetivo descrito.

Desarrollo de la metodología

Se pretende definir el número óptimo de transductores que son económicamente viables, y los valores límite o umbrales, con los que los administradores de infraestructuras pueden tomar decisiones en materia de seguridad de la circulación.

La metodología se compone de tres fases tal y como se ha mencionado anteriormente. En términos generales, esta metodología es apropiada para infraestructuras ya existentes y que

se consideran críticas o deseables de monitorizar.

Para ello, se va a tratar de simplificar a la mínima expresión la cantidad de sensores y tecnología a instalar, de cara a la monitorización y predicción de condiciones degradadas, (por cuestiones puramente económicas y de viabilidad técnica).

Para nuevas infraestructuras, se recomienda implementar desde el principio un sistema de monitorización en tiempo real que cumpla con tal fin, robusto y alineado con la tecnología más apropiada existente en el estado del arte.

En la figura 4.18 se presenta un diagrama de flujo de la metodología propuesta.




Figura 4.18: Diagrama de flujo de la metodología propuesta.

La primera fase de la metodología persigue determinar los puntos críticos que deben estar sujetos a una monitorización constante, y se desarrolla en dos partes diferenciadas. En la primera parte se entrena un algoritmo Random Forest, que predice la respuesta de las aceleraciones en los estribos del puente.

A partir de este algoritmo, en la segunda parte de esta fase 1, se analizan estos datos mediante un algoritmo *SHAP* (*shapely additive explanations*). A través de este algoritmo, se realiza un estudio de significancia para determinar cuáles son los puntos con mayor influencia en la predicción de dichas aceleraciones. Estos puntos serán los mínimos imprescindibles que definan el estado de salud de la infraestructura.

En la figura 4.19 se muestra con más detalle el diagrama de flujo de la fase 1 de la metodología.




Figura 4.19: Fase 1 de la metodología propuesta.

Los acelerómetros identificados en el apartado anterior pueden predecir la respuesta en un punto crítico de la infraestructura. Sin embargo, hay dependencia entre todos ellos, y reducir el número de acelerómetros implicados en la predicción anterior disminuye la precisión. En esta sección, se crea una red neuronal *LSTM* para cada acelerómetro de forma independiente, como se ilustra en la figura 4.20.

Es claro que, cuanto más algoritmos independientes se definen, más coste computacional existe por el entrenamiento y la implementación de cada uno de los modelos. Pero dependiendo de los problemas tratados, es necesarios en ocasiones particular un modelo para un sensor o un elemento en concreto.




Figura 4.20: Fase 2 de la metodología propuesta.

En la fase 3 se entrena el algoritmo y se definen los umbrales de error que establecerán las restricciones de circulación.

Se emplean técnicas específicas para evitar el sobreajuste de los modelos, uno de los mayores problemas en el uso de redes neuronales. El modelo diseñado debe generalizar la solución para cualquier caso, y no solamente para los que ha sido entrenado.

Para ello se debe entrenar con una gran cantidad de datos, que representen todo el universo de posibilidades entre las que deberá trabajar el algoritmo. Después del entrenamiento, se deben establecer los valores límite que se consideren para la detección de un comportamiento anómalo de la infraestructura, siendo estos valores umbrales los detonantes, a la hora de lanzar alertas al administrador de la infraestructura o responsable del mantenimiento de ésta.

En la fase 2 se han generado algoritmos que predicen el resultado, en cada una de las posiciones críticas identificadas de forma independiente y se evalúa el error. Existen varios tipos de errores como se ha descrito anteriormente en el apartado de base teórica.

Se entiende por error la diferencia entre el valor real y el valor obtenido de la predicción. Una vez entrenado el modelo, cuando el error es mayor de lo esperado, esto es, la predicción se aleja considerablemente de la realidad, puede deberse a dos motivos principalmente: o bien se ha producido un error de medición de algún sensor o acelerómetro, o bien se ha producido un cambio en el comportamiento dinámico de la estructura.

Una vez entrenadas las redes neuronales, se establece un sistema de puntuación que clasifica el comportamiento de la estructura, en función del error obtenido en cada predicción de cada red *LSTM* entrenada. Se han establecido tres categorías o zonas de comportamiento en base a los valores de error obtenidos del modelo: zona segura, zona límite y zona crítica.




Figura 4.21: Fase 3 de la metodología propuesta.

Estas categorías se han establecido a partir de un criterio experto, en función de las aceleraciones habituales que se registran con el paso de los trenes por dichas infraestructuras, en condiciones normales de operación.

Como la metodología propuesta en este trabajo consta de un conjunto de redes *LSTM* independientes, el error de medición se descarta fácilmente mediante un sistema de votación. Si todas las predicciones son correctas menos una, es claro que existe un error en el registro de ese acelerómetro o sensor, ya que la respuesta de una estructura corresponde a un registro anómalo de aceleraciones en su conjunto, no solamente en un punto (por cuestiones meramente físicas). Por este motivo se deben posicionar distintos sensores y acelerómetros de acuerdo con lo concluido tras el algoritmo *SHAP*.

Cuando el error de predicción es generalizado, pese a presentar tasas de error distintas en los diferentes puntos, nos encontramos con un comportamiento dinámico de la estructura no esperado, y que podría suponer un riesgo para la seguridad. Puede deberse a distintos motivos: o bien puede existir un deterioro en el material de la estructura que altere la rigidez o el amortiguamiento, o bien puede deberse a factores externos a la estructura que puedan afectar de manera directa a su comportamiento dinámico, como fuertes lluvias o nevadas.

En este artículo, se aplica esta metodología al estudio de un puente concreto de la línea ferroviaria Madrid – Cádiz. Las fuertes lluvias tienen dos principales consecuencias graves para este puente:

- Acumulación de agua en la superficie del puente donde se fijan los raíles, lo cual afecta al peso y al comportamiento dinámico del puente.
- Un incremento del caudal del río que pasa por debajo del puente que además de afectar al comportamiento dinámico, podría provocar inundaciones, causando situaciones de riesgo para el paso de un tren por el puente.

En 2005 se llevó a cabo un experimento para determinar los modos de vibración del puente y otras características técnicas, como la rigidez o los parámetros de amortiguación.

El puente consta de un único vano central y dos apoyos laterales (estribos). El vano se divide en cuatro tableros independientes (dos para cada sentido de circulación).

Los tableros 1 y 3 corresponden a una pista y los otros dos a la otra pista. Esto se representa en la Figura 51. El estudio se centró en uno de los vanos, sensorizándose el tablero 1 el primer día y el tablero 2 el segundo día. Se observó la respuesta del puente al paso de trenes en ambos sentidos de circulación.




Figura 4.22: Estructura principal del puente.

Para una buena caracterización de comportamiento dinámico del puente con el paso de diferentes tipologías de tren, se instalan un conjunto de acelerómetros en distintos puntos para poder registrar los valores y trabajar con los mismos.

Se han utilizado dos tipos de sensores: acelerómetros y sensores de distancia láser. Los acelerómetros se han colocado en las vigas centrales de cada vano, en los tableros, en los estribos y en una de las traviesas de la vía que se ha estudiado. Los acelerómetros se fijan con material adhesivo y en orientación vertical.

Los sensores láser se han posicionado en el punto medio de cada una de las vigas centrales. En la figura 4.23 se puede observar una representación de la distribución y ubicación de los sensores y acelerómetros.

Todos están ubicados debajo del puente excepto el sensor número 10, que se ha ubicado en una de las traviesas de la vía férrea.

El sensor S2 se ha posicionado junto al sensor S13 (información redundante), por lo que solo se consideran datos del S2 para la predicción realizada en este estudio.

El sensor S6 se colocó en la viga 1 pero como la confiabilidad de las medidas era baja, se ha decidido no emplear estos datos para el modelo predictivo.

Siempre es recomendable emplear sensores redundantes para garantizar la fiabilidad de los datos obtenidos. Como se ha comentado anteriormente, una fase fundamental en todo problema de tratamiento de datos e inteligencia artificial, es la recogida de datos. La información debe cumplir siempre los siguientes 3 requisitos:

- Ser fiable.
- Ser íntegra.
- Estar disponible.

Cumpliendo las características anteriores se podrá garantizar una base de datos robusta de cara al tratamiento de datos posterior mediante algoritmos de inteligencia artificial.




Figura 4.23: Diagrama de los sensores instalados.

La posición de todos los sensores se acordó previamente con el cliente, como experto en infraestructuras ferroviarias. Como se puede apreciar en la figura 4.24, la altura del puente es muy baja, por lo que es muy importante determinar si se está produciendo una inundación del río que pueda afectar de manera directa a la operación de los trenes y, por tanto, a su seguridad.



Figura 4.24: Puente sensorizado y estudiado en este artículo.

En total se registraron 25 pasos completos de trenes sobre el puente, de los cuales 3 de estas situaciones corresponden a días de intensa lluvia. La tipología de los trenes registrados es diferente: trenes de mercancías, trenes regionales y trenes de larga distancia. Esto asegura la obtención de conclusiones generales para todas las tipologías de trenes, y el modelo no estará ajustado para ninguna serie de trenes en particular.

La base de datos empleada en este estudio incluye los 22 casos de comportamiento normal del puente, considerando que no existen fuertes lluvias u otras condiciones climáticas extremas. De todos los acelerómetros y sensores, se determina que S1 y S5 son las variables de entrada más influyentes a la hora de determinar un posible comportamiento dinámico anómalo del puente. Esto se obtiene a partir del estudio *SHAP* y tras consulta con expertos en la materia. Los acelerómetros S1 y S5 están ubicados en los estribos laterales del puente, por lo que se encuentran físicamente vinculados a la superficie del mismo, al suelo y al subsuelo que soporta toda la carga de la estructura del puente.

Se aplica la metodología propuesta en este estudio a la base de datos de los 22 casos de comportamiento normal del puente durante el paso de los trenes. Existen por tanto 3 fases diferenciadas que se citan a continuación:

- **Relación entre las variables medidas.** Aplicando el algoritmo *Random Forest* se obtiene la relación entre todas las variables medidas. Es fundamental conocer la relación exacta entre las diferentes aceleraciones de las diferentes partes del puente, para determinar cuáles son las más influyentes para caracterizar la dinámica del puente en condiciones normales (sin fuertes lluvias u otras condiciones climáticas extremas), con el paso de un tren.
- **Predicción de condiciones degradadas.** Aplicando un conjunto de redes neuronales *LSTM* en los puntos clave identificados, se obtiene un modelo predictivo optimizado para determinar el comportamiento normal de las aceleraciones del puente durante el paso de un tren. Si el error obtenido en el modelo comienza a aumentar con los diferentes pasos del tren, significará que se están produciendo cargas adicionales o atípicas, y en el puente estudiado significará una fuerte influencia del agua en el caudal del río, inundaciones del río o incluso acumulación de agua en la superficie del puente, dado que es la causa más frecuente por condiciones climáticas adversas. En esa zona, los vientos son influyentes, pero no en este puente con una altura tan limitada.
- **Evaluación del error y determinación de valores límite.** Para evaluar el desempeño de cada modelo, se definen dos métricas de desempeño: el error absoluto medio (MAE) y la raíz del error cuadrático medio (RMSE). Ambos indicadores son comúnmente utilizados en el estado del arte. A partir de estos valores de error, se llevan a cabo unas ponderaciones que clasifican la estructura en zona segura, zona límite o zona crítica. En caso de entrar en zona crítica, se activarían unas alarmas al gestor de infraestructura e incluso se podrían establecer limitaciones en la circulación de los trenes.

Limpieza de datos

Antes de comenzar con los algoritmos de inteligencia artificial en la fase 1, hay un paso previo fundamental: el proceso de limpieza de datos. Un conjunto de datos robusto y sólido es esencial para obtener resultados fieles y confiables. En este sentido, se realiza un primer estudio de los datos para garantizar la robustez de estos, y obtener así buenos resultados finalmente. Una conclusión inicial del conjunto de datos es que, todas las aceleraciones siguen una distribución normal centrada en 0 y con una desviación estándar muy pequeña.

Todos los valores y datos atípicos se eliminan para obtener un conjunto de datos homogéneo. Los datos medidos son lo suficientemente robustos en general, por lo que se elimina algo menos del 10% de los datos. No hay entradas iguales (filas duplicadas en el conjunto de datos), lo cual es de esperar ya que no hay 2 trenes iguales pasando por el puente al mismo tiempo, y con las mismas condiciones ambientales (temperatura, humedad, ...). El tamaño final del conjunto de datos sin los casos lluviosos (22 viajes), y después del proceso de limpieza contiene aproximadamente 20 000 filas.

En la figura 4.25 se representa un mapa de calor para la correlación de datos: una conclusión importante es que los sensores láser y los sensores de aceleración no están altamente correlacionados, por lo que aparentemente son dos procedimientos de medición diferentes y no aportan información valiosa adicional.




Figura 4.25: Mapa de calor de la correlación lineal de la variable.

El estudio de la matriz de correlaciones se basa en los fundamentos de la dinámica de estructuras. Los modos de vibración de una estructura son ortogonales entre sí, lo que supone una independencia entre sus formas espaciales. Esto se refleja en la matriz donde los acelerómetros ubicados en antinodos del mismo modo de vibración, muestran una correlación mayor ($> 0,5$).

Modelo de *Random Forest* y resultados

Se desarrolla un modelo de regresión *Random Forest* y se implementa un algoritmo *SHAP* para evaluar la influencia de cada transductor en la predicción final del modelo, con el objetivo de detectar acelerómetros redundantes y obtener un número mínimo de sensores que caractericen la respuesta dinámica de la estructura. Estos acelerómetros, se utilizarán en una fase 2 posterior para desarrollar un modelo predictivo basado en redes neuronales recurrentes

(*RNN*).

En la figura 4.26 se muestra un diagrama de la fase 1 de la metodología propuesta.




Figura 4.26: Fase 1 de la metodología (modelo de *Random Forest*)

Se recuerda que, cuanto mayores sean los valores de *SHAP*, mayor influencia tendrá la variable en cuestión respecto al valor objetivo.

Estos acelerómetros se utilizarán en la fase 2 de la metodología, para generar un algoritmo de redes neuronales recurrentes, que detecte la presencia de comportamiento anómalo de la estructura.

Los puntos críticos se encuentran en los pilares. En cada uno de ellos se implementa una red neuronal recurrente (*RNN*), y finalmente se creará un algoritmo de votación, para evaluar la salud estructural a partir de estos modelos independientes desarrollados para cada punto crítico.




Figura 4.27: Fase 1 de la metodología *SHAP*.

En la tabla 4.19 se representa un diagrama con la importancia de cada variable para predecir el valor objetivo. El valor objetivo para predecir es como se explicó anteriormente S1, porque se coloca en el pilar lateral del puente.

Predictor	Importancia
2	0,637
7	0,18
8	0,046
6	0.0286
10	0.0241
5	0.0233
3	0.0232
9	0.0198
4	0,018

Tabla 4.19: Influencia de las variables para la predicción del sensor S1.

Para la predicción de aceleraciones de S1 (sensor de estribo lateral izquierdo según esquema expuesto en la Figura 3), las variables que más influyen corresponden a los sensores S2, S7 y S8. Esto significa que las variables que explicaron mayoritariamente S1 se ubican a un lado de la parte central del tablero monitorizado, en el medio entre el estribo izquierdo y el pilar central del puente.

Como conclusión general de este apartado, colocando únicamente dos sensores en el antinodo del primer y segundo modo de vibración de cada vano del puente, es posible determinar el comportamiento dinámico principal de la estructura considerando la influencia del río, del terreno (subsuelo y suelo) y otras condiciones de contorno. Todas las demás variables de entrada tienen poca influencia y explicabilidad en el comportamiento dinámico global del puente. Por este motivo, la monitorización de este comportamiento dinámico se podría haber ejecutado con estos dos sensores exclusivamente.

Modelo de red neuronal recurrente

El algoritmo de regresión de aprendizaje automático implementado en la fase 1, predice la respuesta del pilar utilizando datos de todos los acelerómetros instalados.

Tras esta predicción, un algoritmo *SHAP* determina las posiciones con mayor impacto en la predicción de las aceleraciones críticas, y por tanto cuya respuesta tiene mayor influencia en la seguridad de la estructura.

En esta fase se desarrolla una red neuronal recurrente (*RNN-LSTM*) para cada acelerómetro. La respuesta estructural se predice en cada uno de los puntos previamente identificados de forma individual, y el error se calcula mediante un sistema de votación.




Figura 4.28: Concepto de la Fase 2 de la metodología.

Una red neuronal recurrente *LSTM* permite predecir el historial temporal de una señal a

partir de una entrada. Por tanto, en este algoritmo, con un único acelerómetro se puede predecir la respuesta del viaducto en ese punto. Sin embargo, durante el funcionamiento, la seguridad nunca debe depender de la fiabilidad de un solo sensor. Para evitarlo existen dos alternativas:

- **Redundancia del acelerómetro.** Si falla un sensor, hay disponible un segundo transductor de respaldo. Esto tiene varias desventajas. La primera es que cuando el fallo de medición se debe a un defecto en la región por causas como la caída de objetos, es probable que no solo se desactive un acelerómetro, sino ambos. La segunda desventaja es que se utilizan dos acelerómetros y sólo se obtiene información de un punto.
- **Colocar acelerómetros en puntos críticos de influencia detectados en el aprendizaje automático.** Con este sistema, el elegido para esta propuesta, se colocan acelerómetros en los puntos críticos y cada uno predice la respuesta en su posición. A diferencia del *Random Forest*, cada acelerómetro solo genera datos para una red neuronal recurrente. Como resultado se implementan tantas redes como acelerómetros. En caso de error en uno de ellos, si el error no se produce en los demás, se puede descartar un estado degradado de la infraestructura y asociarlo a errores de medición.

De acuerdo con los argumentos anteriores, se construyen tres redes neuronales recurrentes *LSTM* para predecir las aceleraciones de S2, S7 y S8 identificados en la fase 1.

La función de activación utilizada en las capas ocultas es la función de activación *ReLU*. Los parámetros se inicializan con la inicialización normal de Glorot (Glorot y Bengio, 2010), aunque existen más opciones de inicializar parámetros como la de He (He et al., 2015); y en la red neuronal se utiliza el optimizador Adam. Todo lo anterior está ampliamente estudiado en el estado del arte de las redes neuronales.

En la tabla 4.20 se especifica la arquitectura de la red neuronal recurrente *LSTM* empleada.

Parámetro	Valor
Batch Size	64
Layer 1	32 kernel filters
Layer 2	64 LSTM neurons
Layer 3	64 LSTM neurons
Layer 4	Dense layer with 30 neurons
Layer 5	Dense layer with 10 neurons
Output layer	1 neuron

Tabla 4.20: Arquitectura de la red neuronal recurrente *LSTM*.

Las tres *RNN* se entrenan, prueban y validan con los 22 pasos de los trenes por el puente. La respuesta dinámica se caracteriza no sólo por los valores obtenidos, sino también por el contenido frecuencial. De hecho, a la hora de diseñar una estructura, las frecuencias naturales son parámetros fundamentales. Por tanto, la bondad de la predicción no puede limitarse exclusivamente a la comparación punto a punto, sino a su representación en el dominio de la frecuencia.

La red propuesta utiliza el *método de ventana móvil*. En este método, el historial temporal se divide en ventanas de igual duración para generar los lotes de entrenamiento. Estas ventanas se mezclan para obtener una bolsa de datos de entrenamiento. Esta división se realiza de forma aleatoria y únicamente con datos que se consideran que siguen un comportamiento normal, es decir, que no corresponden a periodos de inundación. De esta forma, el *RNN* solo aprenderá a inferir el comportamiento normal del puente. El conjunto de entrenamiento contiene alrededor de 20 000 muestras y el conjunto de validación alrededor de 3 000 muestras.

Después de ajustar todos los hiperparámetros y parámetros del modelo, los resultados se exponen en la tabla 4.21, en la que se muestra el MAE en cada uno de los acelerómetros involucrados en la predicción.

% MAE Acc.2	% MAE Acc.7	% MAE Acc.8
11 %	9 %	12 %

Tabla 4.21: . Resultados de entrenamiento de la *RNN*

El indicador clave de desempeño que se emplea para este problema es el MAE. En este caso se concluye que este modelo es capaz de predecir las aceleraciones con un MAE inferior al 20 %.

Así, se podría establecer un límite para detectar una degradación temprana del comportamiento dinámico del puente. Este límite será sugerido en las conclusiones del artículo.

Por otro lado, es importante considerar que este modelo podría extrapolarse a otros puentes o infraestructuras, ya que el estudio se basa en un módulo (tablero) entre dos pilares principales del puente. En caso de que un puente esté compuesto por N pilares, se podría aplicar la misma metodología.

De la fase 1 anterior se extrae que los sensores S2, S7 y S8 son críticos para la seguridad. Para una mejor comprensión del modelo, en las figuras 4.29, 4.30 y 4.31 se muestra la comparación entre los valores predichos y reales. El color naranja representa los valores reales y el color azul los valores predichos.




Figura 4.29: Valores reales versus valores predichos en el modelo *RNN* optimizado de S2.




Figura 4.30: Valores reales versus valores predichos en el modelo *RNN* optimizado de S7.




Figura 4.31: Valores reales versus valores predichos en el modelo *RNN* optimizado de S8.

Como la metodología propuesta en este trabajo consiste en un conjunto de redes neuronales recurrentes *LSTM* independientes, el error de medición se descarta fácilmente mediante un sistema de votación.

Si todas las predicciones son correctas menos una, debido a la ingeniería estructural, es claro que hay un error en el registro, ya que la respuesta de una estructura responde a una serie de características dinámicas que impiden esta aleatoriedad. Cuando el error en la predicción es generalizado, estamos ante un cambio en la estructura que puede suponer un riesgo para la seguridad. Este apartado propone un umbral MAE a partir del cual se deberían proponer limitaciones en la circulación del material rodante, (limitar la velocidad de paso por el puente o incluso suspender la circulación).

Se propone establecer tres áreas compuestas por dos umbrales diferenciados:

- **Umbral límite.** Cuando las métricas superan este umbral, la infraestructura se encuentra en buen estado. En el caso de métricas peores que este valor límite, pero mejores que el umbral crítico, la medición se encuentra en la zona límite. Se propone 0,7 del mejor valor de la métrica obtenida en la validación del algoritmo ó 1/0,7 de MAE. **Umbral**

crítico. Cuando las predicciones muestren valores cuyas métricas sean peores que este umbral, la estructura estará en una zona crítica. Se propone 0,85 del mejor valor de la métrica obtenida en la validación del algoritmo ó 1/0,85 de MAE.




Figura 4.32: Zonas de seguridad y valores límite o umbrales establecidos.

El criterio propuesto depende del número de predicciones con MAE por encima de los umbrales establecido. En la tabla 4.22 se establece el criterio de seguridad basado en lo anterior.

Nº Acc. en zona critica	Nº Acc. en zona límite	Propuesta
1	0	Revisar transductor. LTV.
>2	Cualquier	Circulación cancelada
0	1	Revisar transductor
0	>2	Revisar transductor. LTV.

Tabla 4.22: Criterio de seguridad propuesto.

A partir de las predicciones y aplicando el criterio de seguridad propuesto, se pueden tomar decisiones respecto al mantenimiento y operación de la infraestructura.

Es muy difícil lograr un mejor resultado del modelo, debido a la naturaleza de los datos (sensores de aceleración principalmente) y a que no hay tantos datos disponibles (sólo entre 20

000 – 30 0000 datos considerando que el rendimiento del modelo está altamente relacionado con la cantidad de datos existentes).

Para verificar el buen comportamiento del modelo, se prueban los datos de los 3 viajes en los que la lluvia y el caudal del río están influyendo en el comportamiento dinámico del puente. Se espera obtener mayores errores, lo que significaría una detección de comportamiento dinámico degradado en el puente, y por tanto que el algoritmo cumple con su función.




Figura 4.33: Diferencia entre los valores predichos de S1 (azul) vs los valores reales (amarillo).

Introduciendo estos 3 casos los errores obtenidos por el modelo son muy elevados, por lo que se podría detectar un comportamiento degradado del puente, tal y como puede observarse en la figura 4.33.

La comparación entre los errores RMSE y MAE se encuentra en la tabla 4.23. En esta tabla también se propone un valor límite, para determinar si la influencia de la acumulación de agua o caudal del río está comenzando a afectar el comportamiento dinámico del puente.

Con ello se pretende limitar la velocidad de los trenes durante el periodo de tiempo en el cual la infraestructura esté afectada, y evitar incurrir en ningún riesgo de operación.

	Comp. normal	Comp. degradado	valor límite
RMSE	0,8802	23,0331	1
MAE	0,3746	7,7317	0,5

Tabla 4.23: Comparación entre los valores RMSE y MAE obtenidos en diferentes casos probados.

Conclusiones

A partir de la metodología expuesta se crea un modelo de inteligencia artificial, basado en dos tipos de algoritmos, que es capaz de detectar un comportamiento anómalo o degradado de un puente o de una infraestructura ferroviaria en general.

Una vez determinados los puntos críticos de la estructura, y tras entrenar redes neuronales recurrentes para cada uno de esos puntos críticos, mediante un sistema de votación es

posible caracterizar el comportamiento normal de un puente. A partir del estudio de los errores obtenidos por dichos modelos (MAE), se pueden determinar unos valores límites que detectarían el comportamiento degradado del puente, con tiempo suficiente para poder tomar una decisión referente a la circulación de los trenes por dicho puente.

Este segundo caso de éxito, demuestra la eficacia de emplear la inteligencia artificial en el ámbito del mantenimiento predictivo de las infraestructuras ferroviarias. Esta metodología se puede extrapolar al resto de infraestructuras, y de ese modo generar un concepto de mantenimiento 4.0 en esta área determinada. Mediante la monitorización de las variables más relevantes que caracterizan el comportamiento normal de las infraestructuras, a partir de la aplicación de la inteligencia artificial podemos predecir cualquier comportamiento degradado. Esto es fundamental de cara a mantener la seguridad de la operación, evitando incurrir en riesgos innecesarios.

Gracias a estas predicciones se pueden establecer las acciones necesarias con tiempo suficiente para mitigar los riesgos, o incluso eliminarlos antes de que puedan afectar a la operación ferroviaria.

4.3.3 Caso 3. Predicción de fallos de rodamientos ferroviarios por altas temperaturas.

El sobrecalentamiento de los rodamientos o las aceleraciones anómalas, son dos modos principales de fallo de este componente de seguridad.

La supervisión del comportamiento del rodamiento es fundamental para garantizar un funcionamiento seguro y fiable.

El fallo de un componente de seguridad puede provocar una limitación temporal de velocidad, o incluso una no disponibilidad del tren para operar, por lo que un mantenimiento predictivo de los rodamientos y otros componentes críticos es imprescindible para los fabricantes, operadores y mantenedores del sector ferroviario.

Existen diversas variables que se miden en tiempo real en un tren cada segundo, concretamente: la temperatura de los rodamientos, la temperatura exterior y la velocidad del tren, entre otras muchas.

Objetivo

A partir de todos los datos recopilados y almacenados en los últimos años, en este artículo se diseñan y entrenan redes neuronales para detectar anomalías en los rodamientos de los ejes de un tren, dos días antes de que se detecte un comportamiento anómalo. Dicho comportamiento puede afectar directamente a la seguridad.

Se expone la metodología para la obtención del algoritmo óptimo. Y se comparan diferentes redes neuronales artificiales basadas en diferentes modelos de optimización, como el *Mini-batch Gradient Descent (MGD)* o el optimizador Adam Ruder, [2016](#).

La red neuronal final propuesta posee 10 capas ocultas, y es capaz de detectar rodamientos defectuosos con un 99 % de exactitud, un 95 % de precisión y un 90 % de sensibilidad.

Por tanto, el objetivo de predecir una anomalía en un rodamiento con días de antelación se alcanza con un alto nivel de precisión. Esto supondrá también un ahorro de costes económicos y energéticos, alineado con las políticas de sostenibilidad ya mencionadas en la introducción de esta tesis doctoral.

Este artículo, trabaja con redes neuronales de las ya presentadas en los otros casos, por lo que no se repite de nuevo la parte teórica ya explicada anteriormente.

En este estudio no se consideran series temporales, por lo que la predicción se basa en la interrelación entre todas las variables medidas en tiempo real que rodean al rodamiento. La influencia de la variable temporal en este estudio de temperaturas de rodamientos, no es tan relevante como la relación entre las diferentes variables físicas medidas en cada segundo, debido a la inercia térmica de estos componentes. Dicho de otro modo, la temperatura de un rodamiento no cambia radicalmente de un segundo a otro por inercia térmica, por lo que la detección de anomalías viene determinada por el comportamiento en cada instante de tiempo de todas las variables monitorizadas.

Metodología

El estudio se aborda como un problema de clasificación binaria, en el que los rodamientos deben clasificarse como rodamientos sanos (clase 0) o rodamientos defectuosos (clase 1).

La arquitectura se va evolucionando en cada paso, incrementando progresivamente el número de neuronas en cada capa y el número de capas ocultas en la red. Asimismo, se introducen varias mejoras en los algoritmos de optimización del modelo que mejoran su rendimiento, respecto a modelos anteriores. Estas mejoras requieren el ajuste de nuevos hiperparámetros en el modelo, lo que aumenta la complejidad y el tiempo necesario para entrenar los parámetros del modelo hasta que converja hacia una solución.

Como en todo problema de inteligencia artificial, es fundamental el tratamiento y limpieza de los datos.

El primer paso es adquirir, procesar y filtrar los datos, para poder trabajar con un conjunto de datos confiable y robusto. Para ello se recogen vectores de datos para cada instante de tiempo, de cada una de las ruedas de un eje del tren. Cada vector contiene las siguientes variables:

- Temperatura exterior (v_1).
- Velocidad del tren (v_2).
- Temperaturas de los rodamientos ($v_3 - v_6$). Existen dos rodamientos por cada rueda. Presión de freno (v_7).

Además, para aumentar las muestras y disponer de un número elevado de datos, se incorporan varios trenes de la misma serie.

En la figura 4.34 se representa la distribución de los rodamientos en cada eje del tren, formado a su vez por dos ruedas y dos rodamientos por rueda. Existe por tanto un rodamiento interior y un rodamiento exterior para cada rueda.




Figura 4.34: Distribución de rodamientos y sensores en un eje del tren.

Se espera una correlación lineal muy alta entre las variables medidas. Por ejemplo, una temperatura exterior elevada o altas velocidades en tramos de vía recta, provocarán temperaturas más altas en los rodamientos. De manera similar, la aplicación de una presión de frenado alta provocará fricción y, a su vez, disipación de calor a los rodamientos, aumentando la temperatura de estos componentes.

El tratamiento inicial de los datos es esencial para garantizar una solución robusta del problema. Cuanto más fiables sean los datos iniciales, más preciso será el modelo de predicción diseñado.

Los errores de los sensores, los datos poco fiables y los valores atípicos recurrentes perjudican gravemente el rendimiento del modelo y, por este motivo, deben eliminarse de las muestras. A modo de ejemplo, se eliminan para el estudio los siguientes casos: datos considerando temperaturas de 255° lo que significa fallo de conexión eléctrica del sensor o datos considerando 0 km/h como velocidad del tren. Este último caso, puede deberse a que el tren se detiene en una estación o entra en el taller por inspecciones de mantenimiento, por lo que no son muestras representativas del funcionamiento en servicio de un rodamiento, que es lo que se pretende estudiar.

En problemas de clasificación binaria, es importante que haya una mínima cantidad de muestras de cada grupo a clasificar (aunque uno de los grupos sea minoritario).

Una de las funciones más empleadas en estos problemas, es la función de coste de entropía cruzada. Debido a la naturaleza del problema, hay muchos más datos disponibles sobre el comportamiento normal de los rodamientos en servicio (clase 0), que sobre rodamientos defectuosos (clase 1). Para mitigar el problema, se añade un hiperparámetro final δ en la función de coste (4.4), para ajustar manualmente la contribución de cada clase en esta función de la siguiente manera:

$$L(\hat{y}^{(i)}, y^{(i)}) = [-\delta \cdot y^{(i)} \cdot \log \hat{y}^{(i)} - (1 - y^{(i)}) \cdot \log(1 - \hat{y}^{(i)})] \quad (4.4)$$

Este ajuste debe realizarse de forma muy minuciosa para evitar que se produzca un exceso de falsos positivos (clasificar los rodamientos normales como defectuosos).

Para evitar el sobreajuste, que es un fenómeno que ocurre en los algoritmos de aprendizaje automático como resultado de un entrenamiento excesivo sobre un conjunto de datos con resultados conocidos, se añade un término a la función de coste (4.5) como factor correctivo:

$$J(\mathbf{W}, b) = \frac{1}{m} \sum_{i=1}^n L(\hat{\mathbf{y}}, \mathbf{y}) + \frac{\lambda}{2m} \sum_{i=1}^L \mathbf{W}^{[l]^2} \quad (4.5)$$

Después de la fase de propagación hacia atrás, se actualizan los parámetros del modelo. Para esta última fase se definen múltiples métodos y optimizadores. En este trabajo se ha utilizado inicialmente un algoritmo muy simple: el método del gradiente. Posteriormente se ha implementado un optimizador más complejo como el optimizador *Adam* (*Adaptive Moment Estimation*), con el fin de disminuir el tiempo de entrenamiento de cada modelo, iterando con mayores velocidades a través de diferentes arquitecturas de redes neuronales.

Se definen tres conjuntos de datos tal y como se ha explicado en los casos anteriores.

En un problema de clasificación binaria, los resultados se clasifican como positivos ($p/1$) o negativos ($n/0$).

De este modo, las predicciones realizadas se pueden agrupar en cuatro casos: verdaderos positivos (el resultado de la predicción es 1 y el valor real es 1), falsos positivos (el resultado de la predicción es 1 y el valor real es 0), falsos negativos (el resultado de la predicción es 0 y el valor real es 1) y verdaderos negativos (el resultado de la predicción es 0 y el valor real es 0).

De cara a evaluar un modelo de clasificación binaria como el que se ha planteado, existen distintas métricas definidas a continuación:

- *Accuracy*: es una medida de lo que acierta el modelo, dado que compara los verdaderos positivos y negativos acertados por el modelo entre el número de casos totales.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

- *Precision*: mide el rendimiento en la detección de casos defectuosos, dado que divide los casos defectuosos acertados por el modelo entre el total de casos defectuosos detectados. Se puede decir que calcula la probabilidad de que una predicción positiva resulte positiva.

$$Precision = \frac{TP}{TP + FP}$$

- *Recall*: representa el porcentaje de casos positivos que han sido identificados como tales.

$$Recall = \frac{TP}{TP + FN}$$

Finalmente, para reducir el sesgo y la varianza de los modelos (Geman et al., 1992), se aumenta el número de capas ocultas y se desarrolla el proceso de regularización para asegurar la mitigación de estos dos conceptos.

Modelos y resultados

En este estudio se definen modelos con dificultad creciente, para comparar los resultados y determinar el modelo más adecuado para esta aplicación real de detección de rodamientos defectuosos, antes de que se produzca un fallo en servicio comercial.

Se dispone de una tabla con incidencias de rodamientos durante distintos servicios comerciales, por lo que se propone un modelo supervisado. Hay pocos casos de fallo en comparación con los casos de buen comportamiento tal y como se espera.

Pero existen diferentes alternativas para corregir este problema. Todos los datos recogidos en un coche 48h antes de la detección del fallo, se clasifican como rodamiento defectuoso (clase 1), de tal manera que se está caracterizando un comportamiento anómalo de un rodamiento, al menos con la información que presenta 2 días antes de su fallo.

Estas detecciones de fallos se obtienen de los registros de mantenimiento, una vez que se han retirado los rodamientos y el departamento de calidad ha confirmado que se trataba de un fallo real.

Tras la fase de preprocesamiento de datos se obtienen 1 503 627 ejemplos de entrenamiento: 127 430 ejemplos pertenecen a rodamientos defectuosos y 1 376 397 a rodamientos que se encuentran en buen estado. El resultado es una matriz de datos $\mathbf{X}$ (entrada del modelo) de dimensiones $[1\ 503\ 627; 7]$ con una matriz de datos $\mathbf{Y}$ correspondiente (salida del modelo) de dimensiones $[1\ 503\ 627; 1]$. Las columnas $\mathbf{X}$ contienen la siguiente información, de izquierda a derecha: temperatura exterior (v_1), velocidad del tren (v_2), temperaturas de los rodamientos ($v_3 - v_6$) y presión de freno (v_7).

Debido a limitaciones de cálculo de los ordenadores empleados, se aplica una reducción a 200 000 ejemplos, en una proporción de 1:1, seleccionando aleatoriamente 100 000 datos de la clase 0 y 100 000 datos de la clase 1. Un 90 % de estos ejemplos se utilizarán para el conjunto de entrenamiento, un 5 % para el conjunto de validación y el 5 % restante para el conjunto de prueba.

Se entrenan diversos modelos, variando los distintos hiperparámetros y las configuraciones de la arquitectura de las redes neuronales (Martínez-Llop et al., 2022). Se presenta a continuación el modelo final optimizado con el que se obtienen los mejores resultados.

Modelo final optimizado

El modelo final planteado contiene 10 capas ocultas. Los hiperparámetros seleccionados son los siguientes: dimensión de capa $[7, 100, 100, 100, 100, 100, 100, 100, 100, 100, 1]$; tasa de aprendizaje de $0,3 \cdot 10^{-4}$, parámetro de regularización 0.1; número de épocas 500; tamaño de mini lote 512.




Figura 4.35: Modelo 5: Coste de las iteraciones, resultados del conjunto de entrenamiento, resultados del conjunto de validación.

En la figura 4.35 se muestran los resultados e indicadores definidos anteriormente. Se consigue un modelo final optimizado (modelo 5), obteniendo un accuracy del 99 %, una precision del 95 % y un recall del 90 %, lo que implica un buen algoritmo con altas prestaciones para detectar fallos en rodamientos ferroviarios en servicio.

El hecho de disponer de una base de datos más grande, mejora significativamente el rendimiento del algoritmo. Se aumenta de 8 (modelo 4) a 10 capas ocultas (modelo 5) porque se observa una ligera mejora. Por último, en el artículo queda demostrado que un mayor número de capas ocultas no mejora el modelo. La misma situación se observa con otros hiperparámetros como el número de neuronas, la tasa de aprendizaje, el parámetro de regularización ...

Conclusiones

Tras entrenar diversos modelos de redes neuronales, se obtiene un modelo final optimizado que cumple ampliamente el objetivo de detectar con al menos 2 días de antelación, un posible fallo de un rodamiento ferroviario en servicio. De esta manera, se evitan riesgos de seguridad de la circulación, o problemas de fiabilidad por limitación de velocidad del tren o indisponibilidad de éste para el servicio comercial asignado.

Los primeros modelos entrenados son esenciales para tener una aproximación de los valores adecuados para los hiperparámetros, como el número de capas ocultas, el número de iteraciones...

El modelo final es capaz de alcanzar los mejores valores de accuracy y precisión, simultáneamente (95 % y 90 % respectivamente). El modelo también es capaz de mantener aproximadamente la misma efectividad en el conjunto de pruebas que en los conjuntos de validación y entrenamiento.

Como se puede deducir de los resultados obtenidos en este trabajo, el hiperparámetro más influyente en la efectividad del modelo es el número de capas ocultas en el mismo, seguido del número de neuronas por capa.

Por otro lado, el tiempo de muestreo de los sensores (1 ó 2 segundos) es relativamente pequeño en comparación con los tiempos de ajuste de los transitorios térmicos.

Esta inercia térmica conduce a muchas muestras similares o redundantes, por lo que no es necesario utilizar un parámetro de ajuste muy alto, ya que hay poca variación en los datos para el mismo tipo de fallo.

Como lección aprendida se recomienda aumentar la frecuencia de envío y registro de las temperaturas de los rodamientos ferroviarios, de tal manera que se reducen esfuerzos y costes de computación y almacenaje de información que no aporta valor añadido.

La principal conclusión que se puede extraer de este artículo, es que es posible diferenciar entre rodamientos defectuosos y aquellos en buen estado, prediciendo con alta precisión si el rodamiento puede fallar en los dos días siguientes.

Esta predicción se basa en la correlación del perfil de temperatura en el rodamiento con los demás rodamientos, y variables como la temperatura exterior, la velocidad del tren en ese momento y la presión de frenado.

Debido a la forma en la que se realiza la adquisición de datos, no ha sido posible tener en cuenta el carácter de serie temporal de los datos. Pero el interés de este estudio radica en el hecho de que es posible detectar fallos en los rodamientos, sin tener en cuenta directamente la serie temporal.

La accuracy ($\approx 99\%$), la precision ($\approx 95\%$) y la recall ($\approx 90\%$) obtenidas son excepcionalmente altas.

Hasta hace poco tiempo, los rodamientos simplemente se retiraban cuando el fallo ya se había producido o cuando se activaba la alarma de sobrecalentamiento del rodamiento, lo que no significa que el rodamiento esté necesariamente defectuoso. De hecho, la experiencia mostraba que existían muchos falsos positivos.

Con el modelo final propuesto se puede predecir un posible fallo del rodamiento con 2 días de antelación, evitando el fallo en servicio con sus desastrosas consecuencias, y siendo capaz de planificar con tiempo suficiente la correspondiente parada e inspección de mantenimiento. Si adicionalmente se reducen los falsos positivos, el resultado global da lugar a un modelo robusto de mantenimiento predictivo, que sin duda aporta unos beneficios económicos incalculables para el mantenedor.

Este modelo se recomienda ser implantado en la nube, de tal manera que pueda correrse periódicamente con los datos en tiempo real que va recibiendo de cada uno de los trenes en operación. De este modo, se puede establecer con criterio experto un número de avisos de posible comportamiento anómalo de un rodamiento, de tal manera que se si acumula cierta cantidad, se envíe una alarma y se gestione la inspección detallada del rodamiento en cuestión.

4.3.4 Caso 4. Predicción de la degradación del confort del viajero por deterioro de la amortiguación del tren

En el caso anterior se ha trabajado con la temperatura de rodamientos en el contexto de mantenimiento predictivo. En este caso se va a trabajar con otras de las variables que se monitorizan en tiempo real en los trenes: las aceleraciones transversales y verticales de la estructura de los coches ferroviarios. También se recogen las aceleraciones transversales de la rodadura.

Objetivo

El objetivo del artículo es predecir la degradación del confort del viajero, debido a un comportamiento anómalo de las aceleraciones de la estructura del tren, que es la que recibe el viajero tras pasar por el filtro de los sistemas de suspensión y amortiguación.

Dado que se trata de una variable de seguridad, alcanzados ciertos límites de aceleración en la estructura del coche, denominada caja, se activan unas alarmas que dan lugar a una limitación temporal de velocidad o incluso la parada inmediata del tren, por posibles riesgos de seguridad en la operación. Los valores que se alcanzan para activar dicha alarma son bastante elevados, y además están normativamente preestablecidos.

Sin embargo, en el momento en el que se alcanzan estos valores límite, las aceleraciones han venido siendo excesivas durante bastante tiempo provocando al menos una clara falta de confort en el tren. Por ello, el propósito de este artículo es tratar de identificar con suficiente antelación, el momento en el que el comportamiento de las aceleraciones de la estructura del tren comienza a alejarse de un comportamiento normal. Así, se podrán programar las inspecciones de mantenimiento necesarias, para mitigar el problema antes de que las consecuencias sean mucho peores para el operador o para el viajero.

Desde que las aceleraciones de la estructura del tren empiezan a alejarse de un comportamiento normal, hasta alcanzar el valor límite de seguridad normativo, hay un amplio rango de valores y de tiempo en los que el confort se va viendo cada vez más penalizado.

Por tanto, el objetivo es doble. Por un lado, impedir siempre que se alcancen dichos valores límite de seguridad. Y por otro lado, la detección temprana de una degradación del confort para el viajero, es decir, detectar de forma anticipada el momento en el que el tren está empezando a ser más incómodo de lo estipulado.

A pesar de que el confort no es un concepto incluido en la seguridad, es fundamental de cara a la experiencia de usuario y para fomentar el uso del tren en la sociedad, puesto que de cara al viajero es un parámetro claro de calidad del servicio prestado.

Para esta aplicación, se emplean redes neuronales de las que ya se han visto anteriormente, con el objetivo de elaborar este algoritmo capaz de detectar una degradación el confort del tren, a partir de las aceleraciones medidas en tiempo real.

Datos y definición del modelo

En este estudio se han utilizado datos de un modelo específico de tren de alta velocidad, formado por dos cabezas motrices y 12 coches de pasajeros, pero incluye un total de 13 ejes dado que el coche 6 es de doble eje por la tipología del tren.

En cuanto a la base de datos, cada fila se corresponde con un vector de variables que se registra cada segundo. Nuevamente, como en todo problema de inteligencia artificial que trabaja con datos, se procede en primer lugar con la limpieza y tratamiento de los datos.

Como en el tren se registran muchas variables en tiempo real, se realiza un estudio estadístico con objeto de conocer las variables más influyentes en el problema a tratar.

En este caso de estudio, las variables que se registran en tiempo real en el tren son las siguientes: velocidad del tren (v), temperatura exterior (T_{ext}), temperaturas de rodamientos T_0-T_3 (ya que hay 4 sensores de temperatura de rodamientos por eje), presión de frenado (p), aceleración lateral de la rodadura (a_{yr}), aceleración lateral de la caja (a_{yc}) y aceleración vertical de la caja (a_{zc}) de los 12 coches y 13 ejes del tren.

En las figuras 4.36 y 4.37, se representan a modo ilustrativa las señales que se registran de temperaturas y aceleraciones de los rodamientos de un eje cualquiera (eje 5), para conocer el comportamiento habitual de esas variables a lo largo del tiempo durante un trayecto.




Figura 4.36: Temperaturas de los rodamientos en grados centígrados a lo largo del tiempo.




Figura 4.37: Aceleraciones laterales y verticales (m/s^2) a lo largo del tiempo.

Debido a que se registran dos conjuntos de variables muy distintos como son temperaturas y aceleraciones o velocidad, se realiza un estudio estadístico de componentes principales (*PCA*), (Marukatat, 2022) para determinar cuánto de importantes son las variables relacionadas con las temperaturas, de cara a predecir el comportamiento de las aceleraciones de un coche.

Se verifica que las temperaturas de los cojinetes y la temperatura exterior, son menos relevantes para el comportamiento de aceleración de la carrocería. En la figura 4.38 se representa el *PCA* para las variables correspondientes a un eje a modo de ejemplo.




Figura 4.38: Aceleraciones laterales y verticales (m/s^2) a lo largo del tiempo.

Como se muestra en la figura 4.38, las variables dinámicas (velocidad y aceleraciones) se

representan muy próximas unas de otras, lo que indica la alta correlación que existe entre ellas, mientras que las temperaturas se representan en la dirección opuesta. Este es un fuerte indicador de la independencia física existente entre estas variables.

Como conclusión, las variables térmicas se descartan del conjunto de datos, ya que no proporcionan información esencial y ralentizan la fase de entrenamiento, además de suponer más coste de computación.

Se ha comprobado que incluir estas características térmicas no mejora los resultados. También se elimina la presión de frenado ya que no tiene influencia relevante en el comportamiento térmico o dinámico del tren. Como resultado, en el modelo final de este artículo sólo se incluyen la velocidad y las aceleraciones de cajas y de la rodadura.

En la figura 4.39 se representa la posición de los sensores de aceleración en el tren. En la parte superior del testero de los coches se colocan sensores laterales y verticales de la carrocería. Y el sensor de aceleración lateral de rodadura está situado en la parte central del bastidor de la rodadura. La rodadura en estos trenes se encuentra siempre en la zona de paso entre dos coches.




Figura 4.39: Ubicación del sensor de aceleración en los coches.

El tratamiento inicial de los datos es esencial para garantizar una solución robusta del problema, por lo que se eliminan errores de los sensores, los datos poco fiables, los casos imposibles y los valores faltantes en cualquier variable, que pueden afectar gravemente el rendimiento del modelo. Este paso se ha realizado también en los anteriores casos de estudio, por ser una tarea imprescindible para cualquier problema de inteligencia artificial que trabaje con datos.

Una vez depurados los datos, el segundo paso es considerar únicamente aquellos correspondientes a una velocidad del tren superior a 50 km/h , porque la degradación del confort se nota principalmente a partir de esas velocidades.

En aplicaciones de regresión en las que el objetivo principal es la predicción de valores discretos

en una distribución, el error absoluto se usa comúnmente como función de coste de cada iteración (4.6):

$$L(\hat{\mathbf{y}}, \mathbf{y}) = |\hat{\mathbf{y}} - \mathbf{y}| \quad (4.6)$$

A partir de esta expresión se construye la función de coste del modelo y el MAE (mean absolute error) ya definido anteriormente, con el término correspondiente necesario para evitar el problema de sobreajuste del modelo. Como dato particular, en este artículo se ha utilizado el método de regularización L2 (Breiman, 2001).

De cara a evaluar el desempeño de cada modelo, se definen tres indicadores con unos valores límite obtenidos mediante criterio experto:

- **MAE:** un MAE en torno al 2 % del límite de seguridad determinado en la normativa (“UNE-EN 14363:2017 Aplicaciones ferroviarias. Ensayos y simulac...” [s.f.](#)), es decir 0.05 m/s^2 , se considera un resultado exitoso tras la consulta de expertos.
- **Valor máximo del error:** la obtención de valores máximos de error en alguna predicción inferiores al 10 % de los límites de seguridad normativos, es decir 0.25 m/s^2 , se considerará un resultado exitoso.
- **Contador acumulativo de errores:** esta métrica mide el porcentaje de datos predichos con un error superior a 0.25 m/s^2 . Si menos del 1 % de los datos registrados en un trayecto supera los 0.25 m/s^2 (un 10 % del límite de seguridad de la normativa), se considerará un resultado exitoso.

4.3.5 Modelos y resultados

En este trabajo se han definido diversos algoritmos con una complejidad en la arquitectura ascendente, con el objetivo de predecir aceleraciones laterales de la estructura del tren, para evitar la degradación del confort y detectar deficiencias de amortiguación o suspensión, antes de que se produzca un fallo en operación.

Después de la fase de preprocesamiento de datos descrita anteriormente, el conjunto de datos para entrenar la red neuronal posee 2 millones de muestras. La matriz de entrada $\mathbf{X}$ para la red neuronal es una matriz de dimensiones $[2\,000\,000; 40]$ y el vector que contiene los valores de salida $\mathbf{Y}$ (utilizado para calcular el costo en cada iteración) es un vector de dimensiones $[2\,000\,000; 1]$. Las columnas de la matriz $\mathbf{X}$ contienen las variables descritas anteriormente.

Dado que el objetivo de este estudio es obtener un modelo para aprender y caracterizar el comportamiento correcto de los trenes de alta velocidad en términos de confort, es necesario asegurarse de que el conjunto de datos utilizado para entrenar la red neuronal, no incluya muestras correspondientes a situaciones de comportamiento anómalo, aunque las redes neuronales son bastante resistentes a los valores atípicos.

Se han suprimido también de la base de datos, aquellos correspondientes a días anteriores de detectar alguna anomalía en la suspensión o amortiguación del tren, que pudiera causar una pérdida de confort por aceleraciones excesivas.

De este modo, el modelo está aprendiendo con datos de un comportamiento adecuado del tren, y es capaz de predecir con éxito este tipo de situaciones.

Se obtiene un modelo representativo de un comportamiento normal de las aceleraciones de un tren. Cuando esta red neuronal prediga aceleraciones con un alto error en comparación con la medida del sensor, será un indicativo de comportamiento anómalo de la estructura, y por tanto un posible fallo o deterioro de los componentes de suspensión o amortiguación. Se crean los tres conjuntos de datos mezclados aleatoriamente para evitar sobreajuste.

Un 80 % de las muestras se utilizan para el conjunto de entrenamiento, un 10 % para el conjunto de validación y el 10 % restante para el conjunto de prueba.

Después de varios experimentos probando diferentes arquitecturas en el conjunto de validación de la red neuronal (cambiando hiperparámetros), la arquitectura final definida para el modelo está formada por 6 capas (1 capa de entrada, 4 capas ocultas y 1 capa de salida), y 64 neuronas por capa oculta. En este estudio, los hiperparámetros que se han ajustado son: la tasa de aprendizaje y el parámetro de regularización. La tasa de aprendizaje se ha establecido en 0.001 y el parámetro de regularización en 0.0001.

La razón por la cual el modelo tiene solo 6 capas y 64 neuronas, es porque hacer que la arquitectura de la red neuronal sea más compleja (aumentando el número de neuronas y capas) conduce a un sobreajuste no deseado.

En el modelo obtenido, la aceleración lateral de la estructura de un eje se predice utilizando la información de los otros ejes. Por tanto, se necesita un modelo por cada variable que se quiere predecir, por cada coche o por cada eje.

Sin embargo, la arquitectura de la red y los hiperparámetros permanecen intactos para los diferentes modelos que se generan de los distintos ejes.

De cara a analizar el rendimiento del modelo, se muestra en la tabla 4.24 los resultados del conjunto de prueba de la evaluación de las redes neuronales para cada eje. La red neuronal tarda alrededor de 80 iteraciones (épocas) en converger.

Eje	Error absoluto medio (m/s^2)	Error máximo (m/s^2)
Eje 1	0.0542	0,63
Eje 2	0.0404	0,41
Eje 3	0.0361	0,36
Eje 4	0.0356	0,33
Eje 5	0.0342	0,33
Eje 6	0.0353	0,29
Eje 7	0.0345	0,32
Eje 8	0.0322	0,33
Eje 9	0.0339	0,34
Eje 10	0.0342	0,28
Eje 11	0.0355	0,32
Eje 12	0.0432	0,53
Eje 13	0.0791	1.32

Tabla 4.24: Resultados de la evaluación de las redes neuronales para cada eje sobre el conjunto de prueba.

La tabla 4.24 muestra que, en general, la aceleración se predice con un error absoluto medio de aproximadamente $0.03 m/s^2$ y un error máximo de aproximadamente $0.4 m/s^2$, que se consideran resultados muy positivos. Además, el número de muestras predichas con un error absoluto medio inferior a $0.25 m/s^2$ es del 0% en casi todos los casos.

Cabe destacar que para los ejes 1 y 13 las métricas son ligeramente peores. Se espera este resultado ya que los coches extremos están conectados directamente a las cabezas motrices del tren, y por tanto no se encuentran con el mismo tipo de sistema de guiado. De este modo, la transición en las curvas es más acusada en este tipo de coches extremos, dado que no se preparan con antelación a la entrada en curva por la ausencia del sistema de guiado como el existente entre los coches.

Sin embargo, los resultados para los ejes 1 y 13 están dentro del rango esperado y aceptado, ya que el error para estos ejes significa un 3.2% del límite de seguridad de la normativa de $2.5 m/s^2$.

En conclusión, los márgenes de error obtenidos en las predicciones son prácticamente imperceptibles para los viajeros del tren. Esto significa que el algoritmo es capaz de detectar la degradación del confort, una vez que los sensores de aceleración comparan las predicciones con los valores medidos.

4.3.6 Caso real aplicado del algoritmo

En este mismo estudio, se ha realizado una comprobación de un caso real, en el que un viajero se quejó formalmente al interventor del tren por haber unas aceleraciones excesivas en el coche en el que viajaba. Tras comprobar los datos de las aceleraciones, en ningún caso se alcanzaron los valores límite de la seguridad, por lo que se trata de un caso claro de pérdida de confort en servicio.

Esta red neuronal puede considerarse un modelo *CBM* (*condition – based maintenance*; Fernández-Bobadilla y Martín, 2023), porque es posible lograr una monitorización constante de las aceleraciones, para prever un posible fallo en los componentes de suspensión y amortiguación del tren.

El modelo de red neuronal planteado en este artículo, caracteriza el comportamiento normal de las aceleraciones laterales de la estructura de un coche ferroviario. Por esta razón, es necesario verificar el desempeño del modelo con datos que contienen muestras correspondientes a un comportamiento dinámico normal, y otras muestras correspondientes a un comportamiento degradado de confort (valores elevados de aceleración lateral).

En teoría, el modelo no debería predecir las aceleraciones correspondientes a la degradación del confort del tren con la misma precisión que lo hace para las aceleraciones normales.

Para probar esta idea, se introduce un conjunto de datos completamente nuevo en la red neuronal y se evalúan los resultados de la predicción. Este nuevo conjunto de datos contiene alrededor de 10 000 muestras y las mismas variables que antes (velocidad del tren y aceleraciones para cada eje), pero corresponde a un año diferente al de los datos empleados para el entrenamiento. Estos datos corresponden a un caso particular en el que un viajero sentado en el coche 11 del tren, notó que iba incómodo en su asiento debido al movimiento del tren.

Como el valor límite de seguridad (2.5 m/s^2) no se alcanzó en ningún momento, no se activaron las alertas de seguridad puesto que no se trataba de un problema de seguridad.

Sin embargo, se detectó una clara degradación del confort y se programó una inspección de mantenimiento específica, para comprobar los elementos de amortiguación y suspensión de ese coche número 11. Hubo que corregir la sujeción de un amortiguador, por lo que se descubrió una razón técnica para que se diera esta situación.

Los resultados obtenidos después de correr el algoritmo para predecir las aceleraciones laterales del tren para este conjunto de datos específico se muestran en la tabla 4.25.

	MAE (m/s^2)	Err máx (m/s^2)
Eje 1	0.0611	0,79
Eje 2	0.0518	0,47
Eje 3	0.0251	0,26
Eje 4	0.0217	4.77
Eje 5	0.0263	5.16
Eje 6	0.0379	4.95
Eje 7	0.0354	0,41
Eje 8	0.0523	4.69
Eje 9	0.0634	4.91
Eje 10	0.2321	5.08
Eje 11	0.6467	4,88
Eje 12	0.3523	4,97
Eje 13	0.1162	5.01

Tabla 4.25: Resultados de la evaluación del modelo del conjunto de datos correspondientes al caso específico de la queja del viajero.

Como se observa en la tabla 4.25, las predicciones son extremadamente precisas para las aceleraciones correspondientes a los ejes 1 al 9.

Esto significa que esos ejes están dentro del rango esperado de valores de aceleración lateral correspondientes a un comportamiento normal, por lo que el modelo parece responder de forma correcta.

Sin embargo, para los ejes 10 a 13 las predicciones son extremadamente malas. El modelo genera un MAE de alrededor de $0.4 m/s^2$ en las aceleraciones previstas para esos ejes, y registra más del 60 % de los datos con un error superior a $0.25 m/s^2$.

Teniendo en cuenta que se detectó una degradación del confort en el coche 11 del tren (apoyado sobre los ejes 10 y 11), el modelo queda validado ya que los resultados describen perfectamente la situación ocurrida en ese viaje.

Este es un claro ejemplo de una situación en la que una pérdida de confort se debe a un componente dañado de la amortiguación, pero que no se detecta mediante las alarmas existentes actuales de superación de los valores límites de seguridad.

Por tanto, este modelo puede prolongar la vida útil de algunos componentes del tren, y contribuye con la línea de mantenimiento predictivo a la que se tiende desde hace unos años. Y lo más importante, ayuda a detectar la pérdida de confort del viajero independientemente del motivo técnico que existe detrás, por lo que se contribuye a la mejora de la experiencia de usuario mencionada como punto clave en las líneas futuras de esta tesis.

La implementación de este modelo en el tren, permitirá monitorizar la diferencia entre los valores de aceleración lateral medidos y las predicciones de la red neuronal.

En la figura 4.40, se representan las aceleraciones laterales del coche previstas y las aceleraciones reales del eje número 5: los valores reales se representan en azul y los valores previstos se

representan en rojo. No se detectan diferencias relevantes entre los valores previstos y los reales, por lo que el modelo predice perfectamente un buen comportamiento del eje número 5.




Figura 4.40: Aceleraciones laterales del coche (eje vertical) del eje número 5 versus el tiempo (eje horizontal): valores reales en azul y valores predichos en rojo.

Por otro lado, en la figura 4.41 se representan las aceleraciones laterales del coche previstas y las aceleraciones reales del eje número 11.

Se detecta una diferencia significativa entre los valores previstos y los valores reales, superando los límites establecidos para un comportamiento normal del movimiento lateral del tren. Se detecta una clara degradación del confort en el mismo eje en el que iba sentado el pasajero que alertó del excesivo movimiento lateral del tren durante ese viaje.




Figura 4.41: Aceleraciones laterales del coche (eje vertical) del eje número 11 versus el tiempo (eje horizontal): valores reales en azul y valores predichos en rojo.

En ambas figuras la línea verde representa el límite de seguridad de la normativa (2.5 m/s^2), que no se alcanza en ningún caso. Esto demuestra que se puede detectar una degradación del confort, aunque no sea necesariamente un problema de seguridad, que es el objetivo principal de este estudio.

Conclusiones

Se ha propuesto una red neuronal optimizada con un caso real de aplicación exitosa.

El objetivo principal de este trabajo es obtener un modelo *CBM* con red neuronal capaz de predecir las aceleraciones laterales del coche, para detectar la degradación del confort y la identificación de posibles fallos o deterioros de componentes de la amortiguación o suspensión.

En primer lugar, la monitorización de la degradación del confort se logra, dado que una implementación en tiempo real de la red neuronal permite comparar las predicciones del modelo

(comportamiento ideal), y las mediciones del sensor (comportamiento real). De esta forma, es posible identificar pérdidas de confort si la diferencia entre ambos valores va aumentando progresivamente.

En segundo lugar, se identifican posibles fallos en los componentes de la amortiguación o suspensión del tren, ya que el modelo de red neuronal predice el comportamiento anormal de las aceleraciones laterales de los coches. Con frecuencia, las aceleraciones anormales responden a un comportamiento inusual de estos componentes, por lo que se puede programar una inspección preventiva de mantenimiento, para evitar posibles daños o corregir fallos detectados que pueden derivar en consecuencias más graves para la operación. Por ejemplo el reemplazo de tornillos, soportes aflojados, fijaciones desgastadas, degradación del aceite del amortiguador. . .

Considerando la implementación técnica del algoritmo, un hecho importante es que entrenar el modelo sólo teniendo en cuenta las variables dinámicas del tren es suficiente, tal y como se ha visto tras el análisis *PCA* realizado.

El buen comportamiento del modelo se demuestra en dos vertientes diferentes:

- El MAE obtenido es de 0.034 m/s^2 , inferior al 2 % del límite de seguridad normativo, lo que se considera un resultado exitoso.
- El número de predicciones con errores superiores a 0.25 m/s^2 (10 % del límite normativo) es bastante bajo: 12 veces en la fase de entrenamiento y 5 veces en la fase de prueba. Considerando una cantidad total de 140 000 muestras de entrenamiento y 30 000 muestras de prueba aproximadamente, en menos del 1 % de las muestras se excede el límite, siendo este un indicador importante del buen desempeño del modelo.

Sin embargo, la demostración más importante es el caso de aplicación real, en el que la degradación del confort detectada por un pasajero, fue perfectamente identificada por el modelo: un error absoluto medio de 0.6467 m/s^2 y un contador de error de desbordamiento del 75.1 % excedieron con creces los límites propuestos.

Por tanto, este modelo podría implementarse en el contexto del mantenimiento predictivo. Una vez que se superen los límites propuestos para el error absoluto medio, y el contador de errores registre más de 100 veces un exceso de estos valores de forma consecutiva en menos de 24h, se enviará una alarma al mantenedor.

El significado de esta alarma es la detección de una degradación del confort, o de un fallo inminente del sistema de suspensión o amortiguación, por lo que se podría programar previamente una parada de mantenimiento específica, para corregir esta situación antes de que se produzca la incidencia.

En resumen, se obtiene un modelo *CBM* óptimo para detectar degradación del confort y fallos prematuros del sistema de suspensión o amortiguación, con resultados exitosos considerando errores medios menores a 0.04 m/s^2 , lo que significa valores imperceptibles para los pasajeros.

El estado del arte garantiza la seguridad en los trenes de alta velocidad, pero no existe una monitorización constante del estado de confort en el tren, para asegurar los mejores niveles de confort a los pasajeros, como se propone en este documento para contribuir a la experiencia del usuario. Esta metodología puede ser aplicable a otras variables del tren, sean o no de

seguridad.

4.3.7 Caso 5. Predicción de la degradación del confort del viajero por deterioro de la amortiguación del tren, empleando redes *LSTM*.

Tal y como hemos comprobado en casos anteriores, el aprendizaje automático es efectivo para predecir fallos prematuros de los componentes principales de seguridad de un tren, evitando una pérdida de fiabilidad o disponibilidad durante la operación comercial.

Desde el punto de vista de los viajeros, la puntualidad y la comodidad son dos de los factores más relevantes a la hora de valorar un servicio ferroviario.

El confort se basa principalmente en la disponibilidad de todos los servicios ofertados al viajero en el tren, pero también está relacionado con las aceleraciones recibidas a través de la estructura de los trenes.

La variable más relevante frente al confort del viajero resulta ser la aceleración transversal del (variable denominada a_{yc}). Los elementos de rodadura, de suspensión y amortiguación deben mantenerse en perfectas condiciones durante la operación, para conseguir una dinámica suave en el comportamiento del tren.

En este artículo, se diseña y entrena un modelo optimizado para predecir la falta de confort ferroviario como en el caso anterior, pero esta vez basado en redes neuronales *LSTM* (*long short – term memory*), las cuales son capaces de tener en cuenta la variable tiempo en el modelo. Este modelo se compara con modelos de redes neuronales artificiales (*RNA*) definidos en el caso 4, de cara a evaluar la relevancia de considerar como input la variable temporal.

Esta clase de algoritmos trabaja con agrupaciones de datos en ventanas temporales. En el artículo también se determinará la ventana de tiempo óptima para la agrupación de los datos de entrada, con objeto de obtener los mejores resultados.

Al igual que en el anterior caso, el modelo se entrena con datos correspondientes al correcto comportamiento dinámico del tren. Para comprobar la fiabilidad de este método, se prueba un caso real de movimiento excesivo de trenes tras recibir una queja específica de un viajero.

En estas situaciones se podría enviar una alerta al operador o al mantenedor, para una inspección de mantenimiento no programada en el taller (mantenimiento predictivo), evitando futuras quejas de los pasajeros por la pérdida de confort o, en casos extremos, limitaciones de velocidad por motivos de seguridad, debido a las excesivas aceleraciones percibidas en el coche.

Las principales contribuciones de este trabajo son las siguientes:

- Una red neuronal *LSTM* que, predice aceleraciones laterales de los coches y logra mejores resultados que una red neuronal artificial simple para este conjunto de datos: 0.0335 m/s^2 de MAE y una mejora del 12 % en ejes extremos, en comparación con el modelo del caso anterior.
- Determinación de la ventana de tiempo óptima para agrupar los datos, de cara a ser

introducidos en este algoritmo que tiene en cuenta la variable temporal. Esta venta de tiempo óptima resulta ser 5 segundos.

- Un caso de uso real del modelo en el que, de haber estado en uso, se habría detectado una degradación del confort y se habría podido programar una intervención de mantenimiento, para ajustar los elementos de suspensión o amortiguación y evitar así la pérdida de confort.

Base teórica

Se presenta a continuación un resumen de la arquitectura y concepto de las redes neuronales *LSTM* (*long short – term memory*), que hasta este punto no se han descrito a nivel teórico.

Las Redes Neuronales Artificiales (*RNA*) son una de las técnicas de aprendizaje automático más utilizadas debido a su versatilidad, escalabilidad y rendimiento a la hora de resolver diferentes problemas de regresión o clasificación. Se inspiran en las neuronas biológicas y en la capacidad de nuestro cerebro para realizar cálculos complejos, a través de la interacción mediante la sinapsis de neuronas simples.

En el algoritmo, las neuronas, denominadas perceptrones, están organizadas en extensas capas de diferentes dimensiones (Rojas, 1996).

Las entradas para el primer perceptrón se componen de los datos iniciales recogidos en la matriz $\mathbf{X}$ (variables de entrada) para el problema de predicción. Las entradas del resto de perceptrones resultan ser las salidas de la capa precedente.

Al igual que sucedía en las redes neuronales artificiales, en cada neurona tiene lugar una operación lineal seguida de una operación no lineal, denominada función de activación.

Existen diferentes funciones matemáticas para la parte no lineal. En este artículo se utiliza la tangente hiperbólica (Hwang y Kim, 2023).

La salida de un perceptrón viene dada por la siguiente expresión:

$$h_{\mathbf{W},b}(\mathbf{X}) = \phi(\mathbf{X}\mathbf{W} + b)$$

donde $\mathbf{X}$ es la matriz de características de entrada, $\mathbf{X}$ contiene los pesos y b es el vector de bias.

El vector b es esencial, dado que en caso de tener características que tomen valor 0, no podría tomar la salida ningún valor distinto de 0, por eso es fundamental su intervención y además contribuye a un mejor desempeño del problema.

Como toda red neuronal, debe entrenarse con el objetivo principal de reducir la función de costes definida, puesto que es un reflejo del error de la predicción realizada por el algoritmo. Tras un proceso iterativo, se refuerzan las conexiones entre neuronas reduciendo el error a través del ajuste de los pesos otorgados. En la etapa de propagación hacia atrás se emplea un método de descenso de gradiente (Cai et al., 2023).

Las redes neuronales artificiales (*ANN*) no consideran la dependencia del tiempo ni el orden

cronológico de las entradas. Simplemente se relacionan las diferentes variables entre sí, muestra por muestra. Pero no se tiene en cuenta el orden y, en consecuencia, la dependencia del tiempo.

Para solucionar este problema, se utilizan Redes Neuronales Recurrentes (*RNN*) para considerar la influencia de la variable tiempo, introduciendo memoria a las neuronas. La salida de la neurona en un momento $t1$, se introducirá como entrada nuevamente a la red en un momento t junto con la entrada $\mathbf{X}_t$ (Dyer, 2016). Esto viene representado en la figura 4.42.




Figura 4.42: Estructura de una red neuronal recurrente tipo *LSTM*.

Sin embargo, el rendimiento de las redes recurrentes no se optimiza en casos en los que existen dependencias de largo plazo, debido a problemas con el operador gradiente.

La estructura cerrada de las celdas de *LSTM* permite manejar dependencias de tiempo de hasta 1 000 pasos, considerando dependencias a corto plazo.

En este artículo, se desarrollará un modelo *LSTM* para la predicción del comportamiento normal de aceleración lateral de la estructura de un coche de un tren.

Esta celda se compone de tres puertas diferentes: la puerta del olvido, la puerta de entrada y la puerta de salida. La puerta de olvido decide qué parte del estado anterior de la celda se utiliza. Podría interpretarse como un botón de reset. La puerta de entrada decide cuánta información debe introducirse en el estado de la celda, como si de un conmutador se tratara. La puerta de salida lee el estado de la celda C_{t-1} , y lo combina con la información recibida de $\mathbf{X}_t$ y de $h_{(t-1)}$, para producir la salida h_t tal y como se muestra en la figura 4.43.




Figura 4.43: Estructura de la celda *LSTM* cerrada.

4.3.8 Limpieza y preparación de los datos

El proceso de tratamiento y limpieza de los datos es equivalente al del caso anterior. Una vez realizado este paso, para alimentar la red neuronal *LSTM*, es importante agrupar las muestras de datos.

En este modelo una muestra está compuesta por las mediciones de los s sensores durante t segundos, formando una matriz $\mathbf{X}$ cuyas dimensiones son $t \times s$. Esas matrices se concatenan para formar un vector de entrada a la red neuronal. Para ello, se utiliza un algoritmo de ventana móvil en el tiempo. Dado que se han eliminado varias muestras en el proceso de limpieza de datos, es importante asegurar al realizar los grupos, que se juntan variables de instantes de tiempo correlativos. En este artículo, se estudia y determina la elección adecuada de la ventana temporal considerada para agrupar los datos.

Con respecto a la creación del conjunto de datos de entrenamiento, prueba y validación, es importante resaltar que dos muestras consecutivas no siempre cambian cada segundo registrado, ya que los valores de aceleración son valores estadísticos, calculados como valores cuadráticos medios en intervalos de frecuencia de 5 segundos, ponderadas según la norma EN 12299 (“UNE-EN 12299:2010 Aplicaciones ferroviarias. Comodidad de viaj...” s.f.).

Por esta razón, se decide dividir los meses, asignando febrero y septiembre al conjunto de datos de prueba, abril al conjunto de datos de validación, y los demás meses al conjunto de datos de entrenamiento. De este modo no se aprende el algoritmo muchos datos que son similares entre sí.

La distribución de los datos en el conjunto de entrenamiento, validación y test, se presenta en

la figura 4.44. En esta figura se demuestra que, aunque las muestras corresponden a meses diferentes, el comportamiento dinámico es bastante similar, y no se aprecian diferencias claras en los datos debido a esta división temporal realizada con los datos.




Figura 4.44: Distribución de los datos.

4.3.9 Definición de modelos

Como el objetivo de este estudio es determinar si la arquitectura *LSTM* presenta una ventaja clara, en comparación con un modelo de red neuronal artificial del caso anterior (*ANN*), en el que es independiente del tiempo, la cantidad de parámetros de los modelos *LSTM* debe ser comparable con la cantidad de parámetros utilizados en la *ANN*.

En este contexto, el número de pesos de los modelos probados, está dentro del mismo orden de magnitud que el modelo *ANN*.

Una prueba preliminar ha demostrado que una arquitectura *LSTM* más compleja, no mejora el rendimiento del modelo mientras necesita, más recursos de computación. Las siguientes tres arquitecturas nos permiten evaluar el efecto de las capas ocultas y las celdas *LSTM* apiladas:

- **Modelo 1:** este modelo está formado por una capa de células *LSTM* seguida de una capa densa. La celda *LSTM* captura las características dependientes del tiempo (datos de entrada), y crea una capa de salida de 64 valores, que resumen la información completa contenida en esos datos de entrada. A continuación, se aplica una capa densa.

El objetivo de una capa densa es, relacionar las variables y determinar una predicción de las aceleraciones laterales del coche en cuestión, teniendo en cuenta la salida de las células *LSTM*.

Layer (type)	Output Shape
LSTM cells	(1,64)
Dense	(1,1)

Tabla 4.26: Estructura del modelo 1.

- **Modelo 2:** este modelo demuestra que apilar capas de células *LSTM* puede conducir a mejores resultados. Esta configuración permite que el modelo capture características más complejas que dependen del tiempo. En algunas circunstancias, apilar capas de la red *LSTM* puede mejorar el rendimiento de modelos con un fuerte componente secuencial, por ejemplo, en el procesamiento del lenguaje natural o el procesamiento del habla.

Layer (type)	Output Shape
LSTM cells	(t,32)
LSTM cells	(1,32)
Dense	(1,32)
Dense	(1,1)

Tabla 4.27: Estructura del modelo 2.

- **Modelo 3:** este modelo consta de una capa LSTM y dos capas densas, para capturar relaciones más complejas entre variables, pero no necesariamente relaciones temporales. Dado que considerar una estructura de 6 capas en una red densa permite lograr el mejor rendimiento del modelo, es necesario probar modelos de arquitectura más compleja.

Layer (type)	Output Shape
LSTM cells	(1,32)
Dense	(1,32)
Dense	(1,1)

Tabla 4.28: Estructura del modelo 3.

Para cada modelo, la cantidad de parámetros depende del tamaño de la ventana deslizante de tiempo. Las ventanas de tiempo más grandes conllevan un aumento del coste computacional. El proceso de entrenamiento utiliza el optimizador Adam con una tasa de aprendizaje variable, que se reduce si no se detecta ninguna mejora después de 5 épocas.

Los modelos se entrenan durante 100 épocas, sin embargo, el proceso de entrenamiento finalizará después de 10 épocas consecutivas, si no se detectan mejoras considerables en el conjunto de validación. Además, no se detecta ningún sobreajuste, por lo que no se implementan capas de regularización.

Como se indicó anteriormente, se prueban diferentes ventanas de tiempo: 2, 3, 4, 5, 8, 10, 15, 20, 30 y 60 segundos. No hay claridad sobre el intervalo de tiempo apropiado a considerar en la agrupación de las muestras de datos, ya que la dinámica es una característica que cambia incluso en menos de 1 segundo. Por lo tanto, es difícil determinar científicamente la ventana óptima del lote, por lo que en este artículo se realiza un análisis empírico para establecer la ventana óptima.

Para evaluar el desempeño de cada modelo, se definen los mismos 3 indicadores expuestos en el caso anterior de medidas de errores.

Resultados

Se entrenan varios modelos para predecir la aceleración lateral de la estructura del coche (a_{yc}), por ser la variable más representativa del confort percibido por los viajeros.

Se elabora una red neuronal *LSTM* para predecir la aceleración lateral de cada coche. El primer objetivo del estudio es encontrar el valor óptimo para la ventana temporal de la agrupación de los datos. Para ello se evalúa MAE en el conjunto de prueba. Los resultados para las 3 arquitecturas definidas se muestran en la Tabla 4.29.

	2s	3s	4s	5s	8s	10s	15s	20s	30s	60s
Arq. 1	0,035	0,034	0,034	0,033	0,034	0,034	0,034	0,035	0,035	0,037
Arq. 2	0,035	0,035	0,035	0,034	0,035	0,035	0,036	0,036	0,036	0,037
Arq. 3	0,036	0,036	0,036	0,036	0,035	0,036	0,036	0,036	0,036	0,038

Tabla 4.29: Resultados (MAE medido en m/s^2) de los 3 modelos definidos considerando las diferentes ventanas de tiempo.

Los resultados indican que el mejor valor para la ventana móvil de tiempo a considerar como entrada para el modelo, es 5 segundos para los modelos 1 y 2; y 8 segundos para el modelo 3.

El rendimiento del tercer modelo considerando una ventana de 5 segundos es casi el mismo. Teniendo en cuenta también que el coste informático para una ventana de 8 segundos es mayor que para una ventana de 5 segundos, se concluye que la ventana de tiempo ideal a considerar para la resolución de este problema es de 5 segundos.

La duración de esta ventana de tiempo puede ser diferente en otras aplicaciones, ya que depende en gran medida del comportamiento dinámico de cada tren en particular, y de los datos disponibles. Otra conclusión importante es que las dependencias a largo plazo no mejoran las predicciones, aparte del mayor coste computacional requerido.

Para evaluar la mejor arquitectura del modelo se tienen en cuenta tres métricas. Conviene destacar que el MAE es un buen indicador del rendimiento. Los resultados de los tres indicadores clave de desempeño de cada modelo se muestran en la tabla 4.30.

Modelo	MAE (m/s^2)	Err. máx. (m/s^2)
Modelo 1	0,0335	0,349
Modelo 2	0,0340	0,381
Modelo 3	0,0355	0,309

Tabla 4.30: Indicadores clave de desempeño de los modelos definidos.

La conclusión que se extrae de este experimento es que el mejor rendimiento se consigue con el modelo menos complejo, que es el modelo 1, ya que el MAE es menor, tiene menor porcentaje en el contador acumulativo, y el error máximo parece aceptable considerando los criterios descritos en el capítulo anterior.

Comparativa con el modelo anterior

Otro resultado importante de este artículo es, determinar el valor real de considerar el tiempo como variable fundamental en el modelo. Una vez que se ha seleccionado la duración correcta de la ventana de tiempo, se realiza una comparación entre este modelo que tiene en cuenta la variable temporal (desarrollado en este estudio), y el modelo del caso 4 en el que no se tiene en cuenta el tiempo (ni el orden de las muestras).

Como se muestra en las figuras 4.45 y 4.46 comparando los ejes 1 y 5, se demuestra que todos los modelos desarrollados en este artículo están logrando mejores desempeños que el modelo de independencia temporal desarrollado en (Martínez-Llop et al., 2021).




Figura 4.45: Comparación de desempeño entre el modelo del caso 4 y los modelos desarrollados en este artículo (Eje 5).




Figura 4.46: Comparación de desempeño entre el modelo del caso 4 y los modelos desarrollados en este artículo (Eje 1).

Parece razonable que un modelo de predicción del comportamiento dinámico, que está directamente relacionado con la variable tiempo, tenga un mejor rendimiento que un modelo independiente del tiempo. La inercia, el balanceo, el cabeceo o el momento de guiñada son variables que dependen del tiempo y que afectan a las predicciones.

En la tabla 4.31 se presenta una comparación entre el modelo optimizado (modelo 1) y el modelo de independencia temporal definido en (Martínez-Llop et al., 2023). Se obtienen mejores prestaciones, y un resultado muy interesante es que la ganancia de prestaciones en ejes extremos como el eje 1 es mucho mayor que en otros ejes.

Estos ejes no están guiados, y su comportamiento dinámico es más complejo que el de los ejes intermedios. Por tanto, un modelo dependiente del tiempo tiene más información, ya que también tiene en cuenta estados pasados. Esto sucede porque la *RNA* sólo puede tomar información de los ejes extremos de los valores registrados en los ejes no extremos.

Dado que el comportamiento dinámico de los ejes extremos es diferente, el modelo tiene más dificultades para predecir el valor de aceleración, utilizando únicamente las medidas de los otros ejes. En la red *LSTM*, el modelo puede utilizar el comportamiento del eje extremo en los últimos segundos sumado a la información anterior, y es capaz de lograr mejores resultados.

MAE (a_{yc})	Dense Neural Network (m/s^2)	LSTM Model 1(m/s^2)	Gain (%)
Eje 1	0,0542	0,0400	26,2 %
Eje 3	0,0361	0,0331	8,3 %
Eje 5	0,0342	0,0318	7,0 %
Eje 7	0,0345	0,0329	4,6 %
Eje 9	0,0339	0,0297	12,4 %

Tabla 4.31: Comparativa entre el rendimiento de una red neuronal artificial y el modelo 1.

Caso real aplicado del algoritmo

Como se hizo en el estudio mencionado en el caso anterior (Martínez-Llop et al., 2023), se implementa el modelo 1 sobre el mismo caso real en el que un viajero advierte del movimiento excesivo de la estructura del tren.

Los resultados del caso real de degradación del confort se muestran en la tabla 46. Se detecta un comportamiento anómalo en los ejes 10 – 13, que registran un MAE mayor entre las predicciones y la realidad. Más concretamente, utilizando este indicador y el contador acumulativo de errores, el problema parece estar situado en el eje 11. De hecho, el pasajero estaba sentado en el coche 11, que se apoya entre los ejes 11 y 12.

Este caso de verificación refleja el potencial de este modelo en la definición de un programa global de *CBM*. El modelo de red neuronal puede activar una alarma cuando se detecta una pérdida de comodidad, y mucho antes de que se alcancen los límites de seguridad, la degradación total, o fallo de algún componente mecánico.

Eje	MAE (m/s^2)	Error máx (m/s^2)
Eje 1	0,0725	1,31
Eje 3	0,0454	0,47
Eje 5	0,0357	0,35
Eje 7	0,0436	0,37
Eje 9	0,0426	0,52
Eje 10	0,2076	2,25
Eje 11	0,6320	1,59
Eje 12	0,3534	1,37
Eje 13	0,0996	0,76

Tabla 4.32: Resultados optimizados del modelo 1 del caso real de degradación del confort.

En la figura 4.47 se representa la diferencia entre los valores de aceleración lateral previstos (a_{yc}) y los valores de aceleración lateral reales.




Figura 4.47: Diferencia entre los valores de aceleración lateral previstos (a_{yc}) y los valores de aceleración lateral reales.

Comparando estos resultados con los obtenidos en el modelo independiente del tiempo del caso anterior, ambos experimentos presentan resultados muy similares. Ambos métodos determinaron dónde estaba localizado el problema con rendimiento equivalente.

Conclusiones

Este artículo demuestra los beneficios obtenidos al utilizar modelos dependientes del tiempo, al evaluar las pérdidas de confort debido a las aceleraciones laterales de los coches, mediante el empleo de redes neuronales.

La estructura de la red neuronal recurrente, alcanza rendimientos y resultados mejores en comparación a una red neuronal. La ventana temporal ideal para la agrupación de los datos resulta ser de 5 segundos. Además, el rendimiento disminuye cuando se entrena con una ventana mayor.

Este modelo, al igual que en el caso anterior, detecta la pérdida de confort en un escenario de operación real, donde se identifica el coche en el que existe el problema de desajuste del componente de la amortiguación.

Se recomienda mantener una arquitectura de red neuronal lo más simple posible. Agregar más capas o apilar capas de *LSTM* no siempre mejora los resultados, y al mismo tiempo aumenta la complejidad y los costes computacionales. Otro hecho relevante es que para este estudio, no se han necesitado sensores adicionales a los ya existentes en los propios trenes.

Este estudio pone de manifiesto que el uso de la arquitectura basada en *LSTM*, mejora significativamente el rendimiento de la predicción de los valores de aceleración lateral de los coches, que es la variable relevante en la percepción de confort de los pasajeros. Se obtiene un promedio mínimo de 0.033 m/s^2 como MAE en el modelo 1 agrupando los datos de entrada en paquetes de 5 s como se indicó anteriormente. Este error es inferior al 2.5 % de los valores límite reflejados en la normativa EN 14363.

La precisión alcanzada con estos modelos *LSTM* podría justificar el aumento del coste computacional adicional al de una red neuronal artificial, aunque va a depender de la aplicación en cuestión.

En el caso particular de esta aplicación, el apilamiento de capas LSTM no afecta al rendimiento del modelo, como puede suceder en el procesamiento del lenguaje natural (*NLP*) o en las aplicaciones de reconocimiento de voz.

Además, los modelos *LSTM* son apropiados para estimar la vida útil restante, lo cual se deja como línea futura de investigación (Aydin y Guldamlasioglu, 2017; Shi y Chehade, 2021; Mao et al., 2018).

Una vez detectada la degradación del confort en el tren, es importante resolver en una posible vía de investigación, el tiempo disponible antes de que los pasajeros empiecen a detectar la pérdida de confort notable, o antes de que falle alguno de los componentes mecánicos de la suspensión o amortiguación.

Por lo tanto, una investigación futura podría utilizar la desviación de los datos reales del modelo *LSTM*, como indicador a tener en cuenta al estimar la vida útil restante de dichos componentes.

4.4 Discusión de los resultados y proposición de la metodología de optimización de la movilidad futura.

En vista de lo expuesto a lo largo de este capítulo, se pone de manifiesto el valor añadido que aporta la inteligencia artificial en los distintos campos de aplicación estudiados, aunque se está trabajando de forma aislada desde cada uno de los grupos de interés, sin una interlocución

clara entre estos y sin un objetivo común predefinido. Esto genera soluciones optimizadas de forma individual pero no de cara al sector en general.

El sector tiene ya asumido que debe adoptar este nuevo enfoque de movilidad, evolucionado del tradicional concepto de transporte. Sin embargo, la falta de conocimiento real de los problemas de base y el claro individualismo entre las áreas que intervienen, no están dando los resultados que cabría esperar con la ayuda de las nuevas tecnologías.

En este capítulo, se ha trabajado en el proceso de conocer la demanda real de movilidad en una región determinada, en este caso en España.

A continuación, se ha hecho un análisis, a partir de datos conocidos de acceso público, de la demanda y de la oferta real de transporte existente en España.

Y, por último, se ha demostrado la efectividad y las ventajas que aporta la inteligencia artificial aplicada a cada uno de los grupos de interés que intervienen en la movilidad (operador, gestor de infraestructura, fabricante y mantenedor del material rodante), siendo capaces de obtener soluciones óptimas de manera aislada (mínimos relativos), pero no encontrando la solución global optimizada (mínimo absoluto) para el sector, de manera transversal.

La inteligencia artificial está generando muy buenos resultado en su aplicación en el mantenimiento predictivo. Se trata de una de las áreas más susceptibles de ser optimizadas en una infraestructura o un tren, debido al alto coste asociado durante el ciclo de vida completo. En todos los casos, se consigue predecir con suficiente antelación y precisión, un potencial fallo de seguridad y fiabilidad, relacionado, o bien con el material rodante, (comportamiento anómalo de la temperatura de rodamientos o de las aceleraciones transversales de caja), o bien con la infraestructura (comportamiento anómalo de las aceleraciones del puente).

Esto permite poder tomar decisiones y establecer las mitigaciones oportunas, para minimizar el impacto en la operación y explotación ferroviaria por las causas mencionadas. Estos ejemplos, sirven como motivación para poder ir disminuyendo el mantenimiento preventivo, con objeto de transformarlo en un mantenimiento puramente predictivo, consiguiendo ahorros de un 40 % del total de los costes asociados al mantenimiento correctivo y preventivo en su conjunto (“The International Association of Public Transport | UITP”, [s.f.](#)).

No existen referencias con cifras exactas por motivos de confidencialidad y protección de datos de las diferentes compañías, pero como promedio puede tomarse que de tener un mantenimiento predictivo al menos el 50 % de las inspecciones preventivas de mantenimiento podrían evitarse. Considerando un reparto del 80 % - 20 % entre los costes de mantenimiento preventivo frente a correctivo (Stenström et al., [2015](#)), se puede estimar el 40 % como potencial ahorro por la aplicación del mantenimiento predictivo (“Revista Digital - Efecto de la fiabilidad sobre el coste del mantenimiento. Determinación del intervalo de intervención que proporciona el mínimo coste de mantenimiento.” [s.f.](#)).

A título orientativo, se puede resumir el beneficio total de la implementación de la inteligencia artificial, en los casos expuestos, mediante la siguiente fórmula:

$$A_{et} = \sum 0,5 \cdot C_{pvt} \cdot k_1 + \sum P_f \cdot k_2 + \sum S_a \quad (4.7)$$

donde A_{et} representa el ahorro estimado total por unidad de tiempo (mes, trimestre, semestre

o año), C_{pvt} los costes de mantenimiento preventivo por unidad de tiempo, k_1 un factor corrector que toma valores entre 1 – 1,5 con objeto de absorber ineficiencias y dado que no existen paradas para mantenimiento preventivo de forma exclusiva, k_2 un factor corrector de penalizaciones, que toma valores entre 0,5 – 0,8, dado que no todas se deben a fallos de fiabilidad de componentes principales o no siempre la predicción será exacta, y S_a representa los servicios ahorrados por poder ajustar la predicción de los desplazamientos, que en cada caso y medio de transporte deberá ser especificado por el operador.

Uniendo todas las ideas anteriores, se propone una metodología para la optimización de la movilidad existente, con objeto de evolucionar hacia una movilidad inteligente, en cualquier área, región o país, que cumpla las siguientes características:

- Poseer un conocimiento real de la oferta y de la demanda de movilidad.
- Conocer la prioridad de los trayectos que deben ser reforzados o mejorados para la población.
- Que sea aplicable y escalable a cualquier área, región o país cambiando únicamente las condiciones de contorno.
- Trabajar con las nuevas tecnologías y la inteligencia artificial para reducir la brecha entre la oferta y la demanda de movilidad, y a su vez que ayude a cada grupo de interés a reducir los costes económicos y energéticos de cara a ser lo más eficientes posible, sobre todo aplicado al mantenimiento predictivo tanto de la infraestructura como del material rodante. De este modo se contribuirá a garantizar una movilidad segura, inteligente y de futuro.

Esta metodología, broche final y valor real añadido de esta tesis doctoral, se ha bautizado como “**Transportation**”. Está formada por dos fases diferenciadas. En la primera fase se pretende conocer las necesidades reales de movilidad y la oferta existente, de cara a poder alinear oferta y demanda de la forma más eficiente posible. En la segunda fase entra en juego la optimización de la operación y mantenimiento de los servicios de movilidad, especialmente centrado en el mantenimiento predictivo por razones ya justificadas en este texto, con objeto de alcanzar una movilidad inteligente, eficiente y sostenible.

4.4.1 Fase 1

Los pasos que describe la metodología se citan a continuación:

1. Conocer la demanda real de movilidad por parte de la población, analizando datos de desplazamiento que se hayan recogido de una manera robusta y que sean representativos. Esta información debe ser conocida por las instituciones públicas garantes del servicio de transporte.
2. Detectar el 80 % de los trayectos más demandados por la población en cada una de las regiones o áreas de estudio. Esta información debe ser conocida por las instituciones públicas garantes del servicio de transporte.
3. Analizar los datos concretos de los distintos medios de transporte ofertados a la población,

en los trayectos más relevantes considerados en el paso 2. De esta manera se conocerá la oferta real de movilidad a la que tiene acceso la población.

4. El resto de los trayectos (20 %) pasarán a una prioridad 2, lo que significa que deberán garantizarse de algún modo, pero no serán prioritarios a la hora de encontrar una optimización o de proponer una mayor inversión económica.
5. Determinación de los dos indicadores principales (KPI). En este caso, se debe calcular el tiempo y el coste que supone recorrer 100 km (u otra distancia que se acuerde), a una persona en cada uno de esos trayectos. Estos son los dos indicadores principales definidos en este texto (KPI 1, KPI 2). Analizar los rangos de valores y detectar los casos extremos que necesitan ser mejorados u optimizados. Es una manera de analizar la brecha existente entre la oferta y la demanda.
6. Acordar el valor medio que deben tomar estos dos indicadores, y los valores máximos y mínimos tolerables para un sistema de transportes equilibrado y razonable para todos los ciudadanos.

De lo anterior, saldrá una prioridad de trabajos e inversiones a realizar a futuro, con objeto de preservar los rangos establecidos para los dos indicadores anteriores. Asimismo, esta información es fundamental para poder juntar a los responsables de la planificación de los distintos servicios de transporte, para tratar de cubrir la demanda existente por parte de la población.

Una vez puesto en marcha el proceso de disminuir la diferencia existente entre la oferta y la demanda de movilidad, alineando a todos los que deban participar para resolverlo, en una segunda fase de la metodología se trata la optimización de recursos personales, materiales y, por tanto, económicos y energéticos. Los pasos establecidos en esta segunda fase son:

7. Analizar los problemas más frecuentes o relevantes de la movilidad desde el punto de vista del operador, gestor de la infraestructura y mantenedor de material rodante, con objeto de priorizarlos desde un punto de vista transversal, es decir, con el acuerdo y presencia de los tres grupos de interés. El operador debe ser el responsable de generar esta conversación, al ser la parte interesada principal que está en contacto con las demás.
8. Analizar las sinergias que puede haber entre las partes interesadas, si existieran, para la resolución de dichos problemas: compartición de recursos, compartición de datos e información, ...
9. Determinar los datos e información que es necesario generar para garantizar una movilidad general optimizada.
10. Aplicar la inteligencia artificial para optimizar la solución de los problemas estudiados mediante cualquiera de los algoritmos y técnicas existentes. Especial atención merece el mantenimiento predictivo de infraestructuras y material rodante, por el alto valor añadido que puede suponer en materia de costes y energía a lo largo del ciclo de vida completo.
11. Aquellos problemas no compartidos entre los distintos grupos de interés deberán ser resueltos por cada parte, siendo recomendable el empleo nuevamente de la inteligencia

artificial por las ventajas presentadas y demostradas en esta tesis en diferentes ámbitos de aplicación.

Una vez completados los pasos anteriores se procederá de forma iterativa para asegurar la continuidad de la metodología, ya que se trata de un proceso iterativo y dinámico.

El hecho de poder ir recogiendo en tiempo real información, permite mantener actualizada la demanda de movilidad por parte de los ciudadanos, y la evolución de los distintos problemas analizados por los grupos de interés de cara a su resolución óptima. Esta metodología puede enmarcarse en un programa de mejora continua de movilidad existente de una región o de un país. No se trata de una metodología de implantación desde cero de una movilidad inteligente. En ese caso, debería aplicarse otro tipo de metodología que defina las hipótesis de partida y objetivos, y los datos y tecnología necesarios.

Una vez esta metodología definida en esta tesis esté implementada y se mantenga a lo largo del tiempo de manera activa y dinámica, se podrá asegurar que se ha alcanzado un modelo optimizado de movilidad inteligente, con el objetivo de garantizar la seguridad, la eficiencia económica y energética, y, por tanto, la sostenibilidad.

En la figura 4.48, se muestra de forma esquemática el diagrama de flujo de la metodología expuesta.




Figura 4.48: Diagrama de flujo de la metodología de optimización de la movilidad existente.

Capítulo 5

Conclusiones y líneas futuras

Se ha realizado en esta tesis un estudio completo sobre la situación actual de la movilidad en España. Lo más relevante de este estudio no es la parte cuantitativa, sino la parte cualitativa sobre el progreso del país hacia la mejora de la movilidad existente.

Se recuerda que el objetivo principal es proponer una metodología de optimización de la movilidad inteligente para implementar en los próximos años, tanto a nivel regional como nacional, con objeto de orientarse hacia el nuevo paradigma de movilidad inteligente, tal y como sugiere Europa a través de múltiples entidades como *EU-Rail*.

El estudio de desplazamientos de personas y mercancías se ha presentado a nivel global, sin particularizar en ningún medio de transporte concreto.

El resto de los casos de estudio se desarrollan en el ámbito ferroviario, no solamente por conocimientos del autor, sino porque es el más potenciado desde Europa, para garantizar una movilidad segura y sostenible entre regiones en los próximos años. Sin embargo, podrían haberse planteado casos similares sujetos a optimización, relacionados con el transporte por carretera o con el transporte aéreo.

5.1 Conclusiones principales.

5.1.1 Conclusiones de la evolución del transporte en España.

Tras la realización del estudio inicial sobre el transporte de mercancías y viajeros en España desde el año 2007, se concluye lo siguiente:

- La tendencia no es exactamente fiel a la situación que se encuentra en Europa, aunque presenta ciertas similitudes como puede observarse en la tabla 5.1.
- El número de desplazamientos y de mercancías transportadas en ambos casos es creciente en los últimos años, exceptuando el periodo de pandemia. Esto sucede en todos los países europeos y del mundo en general, debido a que tras la pandemia se trata de recuperar al menos parte de los índices de movilidad existentes en un origen.

- En España, tras la pandemia, la tendencia es nuevamente creciente si revisamos datos más actualizados de los años 2022 y 2023, dado que en 2021 todavía no se ha normalizado la situación. Aun así, no se han recuperado los valores que proyectamos en su día en el año 2007.
- Se detecta un efecto retardado de la situación en España con respecto a la media de los países europeos, aunque es relativamente habitual dado que cada país necesita su tiempo de asimilación, y sus recursos para la implantación de las políticas europeas.
- A nivel nacional, el ferrocarril y el marítimo son los que porcentualmente más viajeros han ganado. En cuanto a las mercancías el único que incrementa su cuota es el marítimo.

2007 – 2019	Nacional	Internacional
Viajeros	Estable	Creciente, alcanza mayores valores
Mercancías	Decreciente hasta 2013	Creciente, alcanza mayores valores

Tabla 5.1: Conclusiones principales sobre el transporte de viajeros y mercancías tanto a nivel nacional como a nivel internacional.

Haciendo hincapié en la movilidad ferroviaria por lo motivos anteriormente expuestos, es conveniente destacar a nivel nacional lo siguiente:

- Es el medio de transporte que ha sufrido a nivel de viajeros mayor evolución, (después del marítimo que presenta una cuota minoritaria de viajeros). En comparación con el 2007, en el ferrocarril se obtiene un aumento de un 35,1 % de la cantidad de viajeros transportados en 2019. Uno de los motivos es el desarrollo potenciado de las líneas de alta velocidad, y la apertura de nuevas conexiones ferroviarias en el país durante los últimos años.
- En referencia al transporte de mercancías, siendo el marítimo el único que logra aumentar la cantidad de mercancía transportada en comparación con el año 2007, el ferrocarril es el que menos cuota de mercado pierde, presentando un 80,2 % de la cantidad de toneladas transportadas en comparación con dicho año.

Se concluye por tanto que en España se ha potenciado mucho el transporte ferroviario de viajeros, y se continúa apostando por aumentar la cuota de viajeros – kilómetro en este modo de transporte.

El crecimiento porcentual es mayor en comparación con el que ha sufrido Europa en los últimos años. En cuanto al transporte de mercancías, también es el que mayor cuota presenta a nivel nacional (después del marítimo), no siendo así a nivel internacional puesto que el ferrocarril ocupa el último lugar. Se está trabajando a nivel europeo en este último punto, para crear corredores de mercancías sólidos e involucrar al mayor número de países posible.

En España, la situación queda alineada con las nuevas políticas europeas de la descarbonización del transporte, y la tendencia a crear una movilidad más eficiente desde el punto de vista energético, hablando así de movilidad sostenible.

A nivel de viajeros se ha visto muy impulsado a través del plan de movilidad nacional, no

quedando tan definida la estrategia de mercancías en los próximos años, en la cual se está trabajando a nivel interno de cara a quedar esa estrategia definida de forma inminente.

En cuanto a la situación europea, dichas políticas continúan en desarrollo e implantación, y deberían revertir la tendencia y encabezar al sector ferroviario, como medio preferido para el transporte de viajeros y mercancías en las distancias apropiadas.

Con ello se pretende además conseguir los objetivos acordados en la Agenda 2030 en materia de sostenibilidad y eficiencia energética.

5.1.2 Conclusiones del estudio de movilidad entre provincias (demanda)

A partir del estudio de los datos aportados por el ministerio desde febrero del año 2020 hasta abril del año 2021, es posible entender la movilidad de las personas entre provincias, esto es, cómo se mueve la población entre las provincias de España. Esto responde a la demanda de movilidad, y es la base para plantear cualquier servicio de transporte.

Los datos de movilidad existen desde hace años en bases de datos abiertas en la web oficial del MITMA, para que cualquier persona que lo desee pueda consultar esta información.

Sin embargo, no existen estudios y análisis detallados que permitan sacar conclusiones sobre la movilidad entre provincias, municipios o distritos. Dicho de otro modo, los datos existen pero no se están invirtiendo recursos en su estudio y análisis detallado.

En base a lo anterior, ni las empresas públicas de transporte, ni las privadas, ni las entidades encargadas de la gestión de los servicios de transporte (ayuntamientos, por ejemplo) están realizando un estudio global detallado con estos datos.

Los servicios de transporte se planifican en base a la experiencia, o con datos que se van actualizando pero que contienen un alto sesgo, y están en manos de una empresa en concreto (como RENFE o EMT).

Por este motivo, el primer paso para plantear una movilidad futura es realizar este análisis a conciencia primero a gran escala (entre las provincias), y luego a menor escala (municipios y distritos).

Es importante corregir esta tendencia y fomentar el análisis de los datos por parte de las entidades correspondientes, para poder sacar conclusiones fiables y poder construir los siguientes pasos de forma robusta y justificada.

En el estudio realizado entre provincias, se obtiene como resultado del trabajo los destinos del 80 % de las personas que viajan de cada una de las provincias (estudio de Pareto). Se obtienen también las siguientes conclusiones:

- Hay provincias que aparecen en ese listado del 80 % de los destinos a donde viaja la población, que son totalmente inesperados o desconocidos por las instituciones públicas.
- No todas las provincias conocen esta información en detalle de dónde viaja la gente de su provincia.

- Muchas conexiones están bien atendidas mediante el ferrocarril o a través de una buena carretera.
- Hay conexiones que no están ni tan siquiera enlazadas de forma directa mediante un trazado ferroviario, y solo puede accederse por carretera.
- Se puede crear una lista de prioridades en las inversiones a realizar en infraestructura y en el transporte en general, conocidas las tablas aportadas en esta sección.

Con la información anterior, es posible asegurar un conocimiento detallado y fiable sobre la demanda de movilidad actual que existe entre las provincias de España. A partir de este primer paso, se estudiará la oferta de transportes a la que tiene acceso la población.

5.1.3 Conclusiones del servicio de transporte entre provincias (oferta)

Para cada uno de los trayectos resultantes del estudio de Pareto realizado en cada una de las provincias, se han estudiado las opciones de movilidad existentes: transporte por carretera, transporte por ferrocarril y transporte aéreo, siempre y cuando exista la posibilidad. Se ha determinado el coste y el tiempo medio para recorrer 100km en cada uno de estos trayectos.

Adicionalmente, se ha determinado qué medio de transporte es más barato y qué medio de transporte es más rápido.

Con toda esta información, se obtienen las siguientes conclusiones:

- No todos los trayectos poseen un enlace ferroviario directo, o un acceso mediante transporte público a una estación de tren.
- Existen provincias en general totalmente desatendidas en materia de transporte público, especialmente en el ámbito ferroviario, como puede ser la provincia de Jaén.
- Existen descompensaciones muy acusadas en materia de costes en algunos trayectos, y en materia de tiempo en otros trayectos. Se debe trabajar en intentar que todos los trayectos estén contenidos en una horquilla que se considere razonable y accesible para cualquier persona.
- No se ha determinado ningún indicador (KPI) global que pueda servir de comparación entre los distintos trayectos y las distintas provincias, con objeto de determinar un orden prioritario en las inversiones de infraestructura y de transporte de cada provincia.

En base a lo anterior, la oferta del servicio de transportes no está planteada en base a la información real de la demanda existente, sino a partir de datos concretos sesgados de las distintas empresas de transporte, o informaciones generales poco concretas de las distintas instituciones de gobierno.

No significa que la oferta no esté correctamente atendida, pero sí es cierto que puede ampliarse la información y evitar los distintos sesgos, con objeto de acercar la oferta y la demanda de transporte que existe realmente.

Además, esta información debe ser dinámica e ir evolucionando con el tiempo, por lo que

conviene ser monitorizada y estudiada de forma periódica. Esto se plantea asimismo en la metodología propuesta en esta tesis.

En base a lo anterior, se debe conseguir una distribución equilibrada de los servicios de transporte, supervisando la situación de forma regular a través de los dos KPI principales que se proponen en esta tesis:

1. **KPI 1:** costes incurridos en recorrer 100 km (€/100km).
2. **KPI 2:** tiempo invertido en recorrer 100 km (h/100km).

A partir de estos dos KPI definidos, se puede controlar de forma regular el equilibrio y distribución homogénea de la movilidad de una región o país. Esto no significa que no se alcancen valores extremos, sino que estén justificados, y que el resto de los trayectos estén en una horquilla razonable en materia de costes y tiempos para los ciudadanos.

5.1.4 Conclusiones de la optimización de la movilidad existente

Analizando la situación de la oferta y la demanda anterior, es necesario un acercamiento entre ambas, con objeto de optimizar la movilidad existente y mejorar la calidad de los servicios de transporte ofrecidos al viajero.

Existen dos posibles soluciones: plantear desde el principio un nuevo concepto de movilidad, lo cual llevaría una inversión muy grande y habría que hacer un estudio mucho más detallado para garantizar una buena transición entre los distintos modelos; y la otra opción es plantear una metodología para poder optimizar la movilidad actual, de tal forma que se aproveche la información existente a través de la aplicación de la inteligencia artificial. En esta tesis, se propone lo segundo, y para ello se han implementado algoritmos y modelos de inteligencia artificial con dos objetivos claros:

- Tratar de acercar la oferta y la demanda de movilidad en base a predicciones, empleando datos públicos conocidos. Se ha comprobado la bondad de los modelos para poder predecir los desplazamientos de las personas, entrenando una red neuronal con el histórico de datos existentes. Esto resulta ser una revolución, el hecho de poder disponer con suficiente antelación de una foto real de la demanda de transporte. Con esta información, es mucho más sencillo poder planificar una oferta de transporte optimizada y acorde a las peticiones de los usuarios, ahorrando costes y tiempos, y evitando incurrir en servicios de transporte que no son necesarios.
- Optimizar la operación y mantenimiento de los servicios de transporte, con objeto de ahorrar recursos tanto personales como económicos, y converger a un modelo óptimo que sea seguro, eficiente y sostenible. Se presentan 4 casos de estudio relacionados con el mantenimiento predictivo tanto de infraestructuras como del material rodante. El motivo es que realizar un buen mantenimiento y ser capaz de predecir situaciones anómalas, logra garantizar un servicio de alta calidad y prestaciones para los viajeros. Además, el mantenimiento es el área de negocio más relevante en cuanto a costes, tanto energéticos como económicos. Este punto es esencial para los grupos de interés principales que intervienen en los servicios de transporte, aunque el usuario final no sea directamente

consciente de esta situación. De forma indirecta, sí que afecta a dicho usuario final, no solamente porque se debe garantizar los máximos valores de seguridad, fiabilidad y disponibilidad de los servicios, sino porque el hecho de que se ahorren recursos tendrá un impacto directo en el precio del billete.

Se logra predecir con resultados suficientemente precisos la movilidad de los desplazamientos, y también potenciales fallos en servicio tanto de componentes del material rodante (rodamientos, suspensión y amortiguación) como de la infraestructura (comportamiento dinámico anómalo por causas climatológicas extremas). Todo ello garantiza una explotación fiable, segura y que contribuye a su vez, en dos de los casos, a la mejora de la experiencia de usuario, pudiendo detectar fallos de confort del viajero, con tiempo suficiente para poder ser corregido a tiempo.

Los algoritmos empleados en las predicciones se basan mayormente en redes neuronales artificiales y recurrentes (*ANN* y *RNN*), dentro del campo del *Deep Learning*. Este tipo de redes neuronales funcionan muy satisfactoriamente para problemas de clasificación o regresión, con un histórico de datos suficiente. En la tabla 5.2 se muestra un resumen del rendimiento de cada una de las redes y el algoritmo empleado.

Caso de estudio	Algoritmo empleado	Mejor modelo
Caso 1	ANN	MAE 5,38 %
Caso 2	RNN – LSTM	MAE 9 %
Caso 3	ANN	Precisión 99 %
Caso 4	ANN	MAE 0.034 m/s^2
Caso 5	RNN – LSTM	MAE 0.033 m/s^2

Tabla 5.2: Mejores modelos hallados en cada caso de estudio.

Los resultados obtenidos ponen de manifiesto las ventajas y potenciales ahorros existentes en el mantenimiento del sector ferroviario, ya sea en la infraestructura o en el material rodante, elementos esenciales para una operación segura y fiable.

Como conclusión fundamental de este apartado, es reseñable lo siguiente:

- Existen un gran número de problemas en el sector ferroviario pendientes de resolver u optimizar, relacionados con la seguridad, fiabilidad, disponibilidad y mantenibilidad.
- Los problemas del sector no se están trabajando desde un punto de vista global y con toda la información necesaria. Esto se demuestra en el estado del arte realizado, en los que se comienza a aplicar la inteligencia artificial, para optimizar y resolver alguno de los retos existentes en el ámbito ferroviario.
- Ante dichos problemas del sector se necesitan soluciones comunes y compartidas. Esto significa preparar una estrategia conjunta con todos los grupos de interés, y que desde el inicio estén presentes en la definición de las posibles soluciones.
- Adicionalmente, es esencial compartir los datos entre los distintos interesados, para poder sacar provecho cada uno desde su negocio o punto de vista. Se deben encontrar las sinergias, en vez de ocultar información que produzca sesgos a la hora de plantear

soluciones globales de movilidad.

- Lo anterior supone un cambio de paradigma, y que tanto las empresas privadas como las instituciones públicas deben de trabajar fuertemente en los próximos años. La información es poder, pero compartida multiplica los resultados y divide los esfuerzos, pudiendo establecerse una relación win – win entre todas las partes interesadas.
- El mantenimiento predictivo es el área más relevante en cuanto a costes económicos y energéticos en el ciclo de vida de un tren o una línea ferroviaria, por lo que su optimización se hace esencial desde todo punto de vista.

El mantenimiento predictivo, más conocido como mantenimiento 4.0 (predicción de fallos ferroviarios en material rodante o en infraestructura), pueden extrapolarse de forma equivalente a cualquier otro tipo de medio de transporte.

Todo ello en su conjunto, pensado desde un punto de vista global, ayudará a optimizar la movilidad existente y conducirla hacia una movilidad inteligente. Servirá a su vez para garantizar los mayores niveles de calidad de los servicios de transporte, en cuanto a fiabilidad, seguridad y disponibilidad se refiere. Para ello, es fundamental seguir una estrategia clara y una metodología ordenada, que en riguroso orden vaya analizando y trabajando la información real para poder aplicar las mejores soluciones.

Esta metodología se ha expuesto en la parte final de esta tesis doctoral, que recoge desde el análisis inicial de la información, hasta la aplicación práctica final de las nuevas tecnologías a la movilidad a través de la predicción de desplazamientos o del mantenimiento predictivo. Incorpora, además, a todos los grupos de interés involucrados.

Con esta metodología, se propone un modelo completo y ordenado para la optimización de la movilidad existente en una región o país, de cara a ser evolucionada hacia una movilidad inteligente. Debe tenerse en cuenta que dicha metodología no trata de esbozar un esquema de implantación desde cero de una movilidad inteligente del futuro.

En cuanto a costes, no se ha realizado un análisis exhaustivo en este trabajo, por no ser el objetivo principal del mismo. No se ha implantado todavía un modelo verdadero de mantenimiento predictivo, aunque se están realizando muchas pruebas tanto en el material rodante como en las infraestructuras. Aun así, en base a la experiencia y los datos analizados, se hace una estimación de un potencial ahorro del 40 % de las intervenciones preventivas, lo cual puede suponer un ahorro muy importante a lo largo de todo el ciclo de vida de un tren o de una infraestructura. En cuanto a la predicción de los desplazamientos, el beneficio claramente existirá por los servicios de transporte que se decidan suprimir por la baja demanda predicha. Ambos ahorros no se consolidan en el acto, dado que por otro lado requerirá una arquitectura de IT, equipos, sensores y personas encargadas de la supervisión continua de los datos para realizar las predicciones.

A título orientativo, tal y como se ha presentado en el capítulo anterior, se puede resumir el beneficio total de la implementación de la inteligencia artificial, en los casos expuestos, mediante la siguiente fórmula:

$$A_{et} = \sum 0,5 \cdot C_{pvt} \cdot k_1 + \sum P_f \cdot k_2 + \sum S_a \quad (5.1)$$

donde A_{et} representa el ahorro estimado total por unidad de tiempo (mes, trimestre, semestre o año), C_{pvt} los costes de mantenimiento preventivo por unidad de tiempo, k_1 un factor corrector que toma valores entre 1 – 1,5 con objeto de absorber ineficiencias y dado que no existen paradas para mantenimiento preventivo de forma exclusiva, k_2 un factor corrector de penalizaciones, que toma valores entre 0,5 – 0,8, dado que no todas se deben a fallos de fiabilidad de componentes principales o no siempre la predicción será exacta, y S_a representa los servicios ahorrados por poder ajustar la predicción de los desplazamientos, que en cada caso y medio de transporte deberá ser especificado por el operador.

Esta metodología, puede ser de aplicación a un medio de transporte concreto, o a todos los medios de transporte en general, en función del alcance que se desee abordar.

También es de aplicación tanto en el ámbito nacional, estudiando la movilidad entre provincias, como a nivel local estudiando los datos de municipios o distritos. Dichos datos también son de acceso público en la página web del MITMA.

Se ha trabajado en un ámbito nacional entre provincias, pero en las líneas futuras se recomienda trabajar también en un ámbito más local, para implementar una movilidad urbana inteligente. Para ello deben estudiarse los datos de municipios y distritos, y tener en cuenta otras condiciones de contorno y medios de transporte en el estudio, (red de metro, autobuses locales o regionales, tranvías, línea de cercanías ...). A nivel local, queda un amplio trabajo por realizar en cuanto a movilidad se refiere, implementando la metodología expuesta en esta tesis doctoral.

Para terminar, cabe destacar que no todas las decisiones políticas, en cuanto a inversión de infraestructuras se refiere, se toman desde un punto de vista meramente técnico. Existen otros muchos factores, subjetivos en muchos de los casos, que influyen en las decisiones políticas.

Por ello, esta metodología pretende ser una herramienta potente cuyo resultado sea una variable de entrada importante a considerar en el ámbito político, a la hora de tomar una decisión sobre las inversiones a realizar en el sector de la movilidad.

Esta metodología puede ayudar, además, a realizar un orden prioritario de las áreas más susceptibles de mejora o que mayor potencial de optimización presentan, de cara a poder establecer las prioridades de las inversiones que deban ejecutarse.

Por último, ayudará a elaborar una estrategia global de movilidad, y una planificación mucho más ajustada y apropiada de los servicios de transporte a ofrecer al ciudadano en un municipio, distrito, región o país.

5.2 Líneas futuras de investigación

A raíz de las conclusiones obtenidas, en este apartado se exponen una serie de líneas de investigación y planes de acción, de cara a dar continuidad al trabajo realizado en esta tesis doctoral. Hay dos factores relevantes que condicionan los próximos pasos a llevar a cabo, que son: los avances tecnológicos existentes y las políticas futuras tanto a nivel regional como a nivel europeo.

5.2.1 Implantación real de la metodología entre provincias.

El primer plan de acción derivado de este trabajo, tiene que ver con la implantación real de esta metodología de movilidad inteligente entre provincias.

En cuanto a la fase I, se debe realizar un estudio similar con los datos más actualizados, y crear un base de datos dinámica que vaya actualizando esta información de forma periódica. Se sugiere la elaboración de una aplicación automatizada que vaya actualizando estos nuevos datos de forma mensual, y vaya aportando esta información a los siguientes pasos de la metodología para actualizar el ciclo completo.

De este modo, se creará una metodología dinámica que sea capaz de mantener la información actualizada de forma periódica, por lo que se asegurará una corrección en tiempo real de la planificación de los servicios de transporte.

Relacionado con la fase 2, se deben sentar a todos los grupos de interés y decidir entre todas las variables críticas a monitorizar para garantizar un estado de salud admisible de la infraestructura, material rodante y operación.

Es suficiente con seleccionar las mínimas variables que se consideren críticas, y asegurar la monitorización en tiempo real.

Por otro lado, de estas conversaciones conjuntas deberán salir proyectos compartidos como puedan ser trenes de viajeros que a su vez actúen como trenes auscultadores, o pódicos de diagnóstico que intercambien información con el tren durante su paso, ...

5.2.2 Futuras investigaciones acerca de la metodología.

Una vez se asegure que la metodología está implantada y funcionando correctamente, aportando un beneficio claro tanto a nivel técnico como a nivel económico, existen múltiples mejoras y líneas de trabajo de cara al futuro que completen dicha metodología entre provincias:

- Aportar información sobre los viajes en avión, en cuanto a tener en cuenta los tiempos de traslado a los aeropuertos y desde los aeropuertos. Incluir una media de retrasos de los vuelos.
- Ampliar las alternativas de transporte y dar diversas opciones en función de si se pretende priorizar el tiempo, el coste o el impacto medioambiental.
- Cruzar esta información de desplazamientos con la trayectoria real en el mapa que se pretenda seguir. De este modo, se puede tener una imagen más clara de los medios de transporte que están empleando las personas en dichos desplazamientos.
- Aumentar el estudio a todos los medios de transporte posibles a emplear en un trayecto.
- Ampliar el número de variables a monitorizar en tiempo real para mantener un buen estado de salud de la infraestructura, la operación o del material rodante. De este modo se asegurarán los máximo valores de seguridad, fiabilidad, disponibilidad y mantenibilidad. Fruto de ello se obtendrán grandes ahorros de costes y potenciar áreas de mejora y optimización.

- Seleccionar algunas variables que además estén relacionadas con la experiencia de usuario, como campo de interés creciente de cara al viajero, que condicionará la selección futura de los distintos medios de transporte a la hora de realizar un trayecto.
- Implementar otro tipo de algoritmos y redes neuronales que logren afinar todavía más en las predicciones realizadas. De este modo, cada vez se podrá adaptar mejor la oferta y la demanda, y se tendrá más margen de maniobra para poder planificar los servicios de transporte con suficiente margen y antelación.
- Establecer indicadores (KPI) adicionales, para la monitorización y seguimiento de la implantación de esta metodología de movilidad inteligente propuesta.
- Desarrollar una arquitectura en la nube con toda la infraestructura anterior de datos, con su correspondiente modelo de protección en cuanto a ciberseguridad se refiere.
- Crear un comité de seguimiento de esta metodología, para asegurar el mantenimiento de este modelo de movilidad inteligente durante los próximos años.
- Afinar el estudio con variables subjetivas: sindicatos, cultura social, ...

Toda la información anterior, completará el estudio global de movilidad inteligente entre provincias, sacando el máximo partido tanto a las herramientas tecnológicas como a los datos existentes y que ya se recogen actualmente.

Otra alternativa futura a partir de lo anterior, puede ir enfocada a definir desde el principio una movilidad inteligente de futuro, para lo cual se necesitarán numerosos recursos y fuentes de información previas a su estudio.

Una tercera línea de investigación futura, tiene que ver con el hecho de implementar este mismo modelo de optimización a una escala inferior, esto es, a nivel de municipios y distritos. La extrapolación del modelo a regiones municipales no es trivial, dado que las condiciones de contorno cambian debido a los siguientes motivos:

- Existen distintas políticas de movilidad en las distintas regiones o ciudades.
- Aparecen nuevos medios de transporte fundamentales, como pueda ser el transporte suburbano (el metro), tranvías o sistemas híbridos como el “Metro Liger” de Madrid.
- Existen muchas más opciones y posibilidades de movilidad en distancias cortas, como las que se realizan habitualmente en las ciudades o municipios.
- No se pueden cubrir por todos los medios de transporte todas los trayectos a pequeña escala, por lo que debe evitarse demasiado solapamiento entre los distintos servicios de transporte, priorizando un sistema homogéneo que permita la accesibilidad a cualquier ciudadano independientemente del municipio o distrito en el que habite.
- Se pueden establecer indicadores (KPI) que den lugar a la monitorización y seguimiento de la implantación de este modelo en un municipio o distrito determinado.

Los campos anteriormente expuestos, tienen que ver con una movilidad urbana inteligente, no habiendo entrado en detalle en esta tesis sobre las particularidades y características que envuelven dicha tipología de movilidad.

Múltiples centros de investigación o laboratorios como el *MIT Media Lab*, están en constante investigación sobre la movilidad urbana del futuro, teniendo en cuenta aspectos técnicos, económicos y sobre todo medioambientales, para garantizar una movilidad inteligente futura y unas ciudades verdes, conectadas, seguras y sostenibles.

Con todo lo anterior, un último gran paso sugerido en esta sección de líneas futuras, es realizar este mismo estudio pero teniendo en cuenta los tiempos y costes del concepto *door – to – door*, esto es, el servicio de puerta a puerta. Cambia totalmente el enfoque y es un nuevo paradigma al que nos vamos a enfrentar en los próximos años.

El medio de transporte pasa a ser de verdad un medio, y el usuario final no tiene ni tan siquiera que preocuparse por las distintas opciones existentes, dado que es una gestión que pasa a realizarse en un segundo nivel.

El objetivo principal es minimizar el coste y tiempo de trayecto de puerta a puerta, es decir, se concibe un viaje sin existir preocupación acerca de los medios de transporte a utilizar y las conexiones. Simplemente entran en juego las dos variables principales que preocupan a todo ser humano en un desplazamiento: el tiempo y el coste. Otros campos como la experiencia de usuario, cogerán un mayor protagonismo en este nuevo enfoque de movilidad.

Durante los próximos años, se va a contemplar un gran cambio en el sector de la movilidad y del transporte, tanto a nivel conceptual, como a nivel de medios. Las nuevas tecnologías y las políticas cambiantes potenciarán el cambio paradigmático, relacionado con la movilidad de las personas y las mercancías.

Lo que sí es seguro, es que seguirá existiendo esta necesidad intrínseca en el ser humano, y de alto interés para los ingenieros, científicos y demás profesionales que se dedican a este complejo, pero interesante sector.

Referencias

- Abdu, D. M., Guo, W., & Wang, Y. (2023). Assessment of railway Bridge pier settlement based on train acceleration response using machine learning algorithms. *Structures*, 52, 598-608. <https://doi.org/10.1016/j.istruc.2023.03.167>
- Açıkgöz, H., & Korkmaz, D. (2023). MSRCONVNET: Classification of railway track defects using multi-scale residual convolutional neural Network. *Engineering Applications of Artificial Intelligence*, 121, 105965. <https://doi.org/10.1016/j.engappai.2023.105965>
- Aggarwal, C. C. (2018, 25 de agosto). *Neural networks and deep learning: A Textbook*. Springer.
- Alawad, H. A. H., Kaewunruen, S., & An, M. (2020). A deep learning approach towards railway safety risk assessment. *IEEE Access*, 8, 102811-102832. <https://doi.org/10.1109/access.2020.2997946>
- Alonso, J., Orue-Echevarria, L., Casola, V., De La Torre, A. I. S., Huarte, M., Osaba, E., & Lobo, J. L. (2023). Understanding the challenges and novel architectural models of multi-cloud native Applications – A systematic literature review. *Journal of Cloud Computing*, 12(1). <https://doi.org/10.1186/s13677-022-00367-6>
- Alpos, T., Iliopoulou, C., & (2022). Nature-Inspired optimal route network design for shared autonomous vehicles. *Vehicles*, 5(1), 24-40. <https://doi.org/10.3390/vehicles5010002>
- Amanna, A., Gadhiok, M., Price, M. J., Reed, J. H., Siriwongpairat, W. P., & Himsoon, T. (2010). Railway Cognitive Radio. *IEEE Vehicular Technology Magazine*, 5(3), 82-89. <https://doi.org/10.1109/mvt.2010.938275>
- Aminzadegan, S., Shahriari, M., Mehranfar, F., & Abramović, B. (2022). Factors affecting the emission of pollutants in different types of transportation: a literature review. *Energy Reports*, 8, 2508-2529. <https://doi.org/10.1016/j.egyr.2022.01.161>
- Arrubla-Hoyos, W., Ojeda-Beltrán, A., Solano-Barliza, A., Ibarra, G. E. R., Barrios-Ulloa, A., Cama-Pinto, D., Arrabal-Campos, F. M., Martínez-Lao, J. A., Cama-Pinto, A., & Manzano-Agugliaro, F. (2022). Precision agriculture and sensor systems applications in Colombia through 5G networks. *Sensors*, 22(19), 7295. <https://doi.org/10.3390/s22197295>
- Arslan, B., & Tiryaki, H. (2020). Prediction of railway switch point failures by artificial intelligence methods. *Turkish Journal of Electrical Engineering and Computer Sciences*, 28(2), 1044-1058. <https://doi.org/10.3906/elk-1906-66>
- Artificial neural networks*. (s.f.). https://books.google.es/books/about/Artificial_Neural_Networks.html?id=v9ErswEACAAJ&redir_esc=y
- Aydin, O., & Guldamlasioglu, S. (2017). Using LSTM networks to predict engine condition on large scale data processing framework. *2017 4th International Conference on Electrical*

- and Electronic Engineering (ICEEE)*, 281-285. <https://doi.org/10.1109/ICEEE2.2017.7935834>
- Balogun, I., & Atttoh-Okine, N. (2023). Covariate-Shift Generative Adversarial Network and railway track image analysis. *Journal of transportation engineering*, 149(3). <https://doi.org/10.1061/jtepbs.teeng-7390>
- Beeckmans, M., Huycke, P., Verguts, T., & Verbeke, P. (2023). How much data do we need to estimate computational models of decision-making? The COMPASS toolbox. *Behavior Research Methods*. <https://doi.org/10.3758/s13428-023-02165-7>
- Bliss, L. (2016). TransitCenter survey finds public transit riders want frequent and fast bus and rail service.
- Blueprint Labs. (2023, 24 de mayo). *New Frontiers: The Origins and Content of New Work, 1940–2018 - Blueprint Labs*. <https://blueprintlabs.mit.edu/research/new-frontiers-the-origins-and-content-of-new-work-1940-2018-2/>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5-32. <https://doi.org/10.1023/a:1010933404324>
- Briguglio, M., & Formosa, G. (2023). Sharing is Caring: An Economic analysis of consumer engagement in an electric vehicle sharing service. *Sustainability*, 15(6), 5502. <https://doi.org/10.3390/su15065502>
- Bugaj, M., Ďurana, P., Blazek, R., & Horák, J. (2023). Industry 4.0: Marvels in profitability in the transport sector. *Mathematics*, 11(17), 3647. <https://doi.org/10.3390/math11173647>
- Cai, Z., Chen, L., Zeng, S., Lai, Y., & Liu, H. (2023). EST-NAS: an Evolutionary strategy with gradient descent for Neural architecture search. *Applied Soft Computing*, 146, 110624. <https://doi.org/10.1016/j.asoc.2023.110624>
- Caixia, M., Wang, Z., Shi, L., Gao, Y., Tao, Y., & Lin, W. (2023). SDRC-YOLO: A novel foreign object intrusion Detection Algorithm in railway scenarios. *Electronics*, 12(5), 1256. <https://doi.org/10.3390/electronics12051256>
- Casquição, M., Mataloto, B., Ferreira, J. C. F. O. J., Monteiro, V., Afonso, J. L., & Afonso, J. A. B. (2021). Blockchain and Internet of Things for Electrical Energy Decentralization: A review and system architecture. *Energies*, 14(23), 8043. <https://doi.org/10.3390/en14238043>
- A category classification based safety risk assessment method for railway wagon loading status. (2023). *Tehnicki Vjesnik-technical Gazette*, 30(6). <https://doi.org/10.17559/tv-20230412000525>
- Çelebi, D. (2023). Supporting rail freight services in Turkey: Private sector perspectives on logistics connectivity issues. *Case Studies on Transport Policy*, 14, 101098. <https://doi.org/10.1016/j.cstp.2023.101098>
- Cerdán, J. (2022). Las 10 grandes tendencias tecnológicas que van a marcar el 2023.
- Change, I. P. O. C. (2023, 22 de junio). *Climate Change 2022 – Impacts, adaptation and vulnerability*. <https://doi.org/10.1017/9781009325844>
- Chen, C., Liu, Y., Wang, S., Sun, X., Di Cairano-Gilfedder, C., Titmus, S., & Syntetos, A. A. (2020). Predictive maintenance using COX Proportional Hazard Deep learning. *Advanced Engineering Informatics*, 44, 101054. <https://doi.org/10.1016/j.aei.2020.101054>

- Chen, J., Tao, S., Teng, S., Chen, Y., Zhang, H., & Wang, F. (2023). Toward sustainable intelligent transportation Systems in 2050: Fairness and Eco-Responsibility. *IEEE transactions on intelligent vehicles*, 8(6), 3537-3540. <https://doi.org/10.1109/tiv.2023.3286873>
- Chen, J., Li, Q., Wang, H., & Deng, M. (2019). A machine learning ensemble approach based on random forest and radial basis function neural network for risk evaluation of regional flood disaster: a case study of the Yangtze River Delta, China. *International Journal of Environmental Research and Public Health*, 17(1), 49. <https://doi.org/10.3390/ijerph17010049>
- Chen, Z. (2017). Impacts of high-speed rail on domestic air transportation in China. *Journal of Transport Geography*, 62, 184-196. <https://doi.org/10.1016/j.jtrangeo.2017.04.002>
- Cheremisin, V., Komyakov, A. A., & Erbes, V. V. (2017). Simulation of power consumption in railway power supply systems with of artificial intelligence aids. *IEEE Xplore*. <https://doi.org/10.1109/icieam.2017.8076242>
- Choi, M., Yoon, B., Kim, D., & Sung, D. (2020). Duplex Communication Method for Railway Vehicle Communication System. *2020 International Conference on Information and Communication Technology Convergence (ICTC)*, 823-827. <https://doi.org/10.1109/ICTC49870.2020.9289349>
- Claessens Martínez, D. (2022, julio). *Estudio de movilidad entre provincias en España para planificar el futuro del transporte sostenible* [No Publicado].
- Cooper, G. (2023). Examining Science Education in ChATGPT: An Exploratory Study of Generative Artificial Intelligence. *Journal of Science Education and Technology*, 32(3), 444-452. <https://doi.org/10.1007/s10956-023-10039-y>
- Coursera | Online courses credentials from top educators. Join for free | Coursera. (s.f.). <https://www.coursera.org/learn/neural-networks-deep-learning/home/week/1>
- Couteau, C., Barz, S., Durt, T., Gerrits, T., Huwer, J., Prevedel, R., Rarity, J., Shields, A. J., & Weihs, G. (2023). Applications of single photons to quantum communication and computing. *Nature Reviews Physics*, 5(6), 326-338. <https://doi.org/10.1038/s42254-023-00583-2>
- Curtale, R., Larsson, J., & Nässén, J. (2023). Understanding preferences for night trains and their potential to replace flights in Europe. the case of Sweden. *Tourism Management Perspectives*, 47, 101115. <https://doi.org/10.1016/j.tmp.2023.101115>
- Da Silva, T. R., Moura, B., & Monteiro, H. (2023). Life cycle assessment of current Portuguese railway and future decarbonization scenarios. *Sustainability*, 15(14), 11355. <https://doi.org/10.3390/su151411355>
- Daniyan, I., Mpofu, K., Muvunzi, R., & Uchegbu, I. D. (2022). Implementation of artificial intelligence for maintenance operation in the rail industry. *Procedia CIRP*, 109, 449-453. <https://doi.org/10.1016/j.procir.2022.05.277>
- Daniyan, I., Mpofu, K., Oyesola, M., Ramatsetse, B., & Adeodu, A. (2020). Artificial intelligence for predictive maintenance in the railcar learning factories. *Procedia Manufacturing*, 45, 13-18. <https://doi.org/10.1016/j.promfg.2020.04.032>
- Davari, N., Veloso, B., Ribeiro, R. P., Pereira, P. M., & Gama, J. (2021). Predictive maintenance based on anomaly detection using deep learning for air production unit in the railway industry. *2021 IEEE 8th International Conference on Data Science and Advanced Analytics (DSAA)*, 1-10. <https://doi.org/10.1109/DSAA53316.2021.9564181>

- De Simone, L., Caputo, E., Cinque, M., Galli, A., Moscato, V., Russo, S., Cesaro, G., Criscuolo, V., & Giannini, G. (2023). LSTM-based failure prediction for railway rolling stock equipment. *Expert Systems with Applications*, 222, 119767. <https://doi.org/10.1016/j.eswa.2023.119767>
- Del Castillo, A. C., Marcos, J. M., & Parlikad, A. K. (2023). Dynamic fleet maintenance management model applied to rolling stock. *Reliability Engineering System Safety*, 240, 109607. <https://doi.org/10.1016/j.ress.2023.109607>
- Desarrollo Sostenible. (2017, 13 de noviembre). *La Asamblea General adopta la Agenda 2030 para el Desarrollo Sostenible*. <https://www.un.org/sustainabledevelopment/es/2015/09/la-asamblea-general-adopta-la-agenda-2030-para-el-desarrollo-sostenible/#>
- Drouet, L., Lallemand, C., Koenig, V., Viti, F., & Bongard-Blanchy, K. (2023). Uncovering factors influencing railway passenger experiences through love and breakup declarations. *Applied Ergonomics*, 111, 104030. <https://doi.org/10.1016/j.apergo.2023.104030>
- Du, J., Li, J., Chaplin, G., Gardiner, A., & Hu, Y. F. (2023). Failure mode analysis and maintenance of railway overhead line rigid stainless steel droppers and Multi-Strand copper jumpers. *IET electrical systems in transportation*, 2023, 1-28. <https://doi.org/10.1049/2023/8858919>
- Dyer, C. (2016, 25 de febrero). *Recurrent neural network grammars*. <https://arxiv.org/abs/1602.07776>
- Echelmeyer, W., Nguyen, T. V., & Mete, M. (2022, 4 de septiembre). *Concept for a revolution of public transport*. https://doi.org/10.1007/978-3-031-16281-7_46
- EN 50126 Railway RAMS Standard: Specification, Verification and Management. (2022, 25 de noviembre). <https://www.izp.de/en-50126-specification-demonstration-rams-reliability-availability-maintainability-safety-case/>
- Erdei, L., Tamás, P., & Illés, B. (2023). Improving the efficiency of rail passenger transportation using an innovative operational concept. *Sustainability*, 15(6), 5582. <https://doi.org/10.3390/su15065582>
- Ersöz, O. Ö., İnal, A. F., Aktepe, A., Türker, A. K., & Ersöz, S. (2022). A systematic literature review of the predictive maintenance from transportation Systems aspect. *Sustainability*, 14(21), 14536. <https://doi.org/10.3390/su142114536>
- Europe's Rail. (2018, 10 de septiembre). *Home - Europe's Rail*. <https://rail-research.europa.eu/>
- Fantini, A., Fiorucci, M., & Martino, S. (2017). Rock Falls impacting railway tracks: Detection analysis through an Artificial Intelligence camera Prototype. *Wireless Communications and Mobile Computing*, 2017, 1-11. <https://doi.org/10.1155/2017/9386928>
- Fariñas Nubla, A. (2021, julio). *Predicción de la movilidad entre provincias de España a partir del histórico de datos del ministerio* [No Publicado].
- Fernández-Bobadilla, H. A., & Martin, U. (2023). Modern Tendencies in Vehicle-Based Condition Monitoring of the Railway Track. *IEEE Transactions on Instrumentation and Measurement*, 72, 1-44. <https://doi.org/10.1109/tim.2023.3243673>
- Foody, G. M., McCulloch, M. B., & Yates, W. B. (1995). The effect of training set size and composition on artificial neural network classification. *International Journal of Remote Sensing*, 16(9), 1707-1723. <https://doi.org/10.1080/01431169508954507>
- Fumeo, E., Oneto, L., & Anguita, D. (2015). Condition based maintenance in railway transportation systems based on big data streaming analysis. *Procedia Computer Science*, 53, 437-446. <https://doi.org/10.1016/j.procs.2015.07.321>

- Garrido Martínez - Llop, P. (2023a, Agosto). *Mobility prediction in Spain applying artificial neural networks* [No Publicado].
- Garrido Martínez - Llop, P. (2023b, octubre). *Prediction of Degraded Infrastructure Conditions for Railway Operation* [No Publicado].
- Geman, S., Bienenstock, E., & Doursat, R. (1992). Neural networks and the Bias/Variance Dilemma. *Neural Computation*, 4(1), 1-58. <https://doi.org/10.1162/neco.1992.4.1.1>
- Geng, G., Zhang, H., Zhu, J., & Zhong, C. (1999). Applying AI to railway freight loading. *Expert Systems with Applications*, 16(1), 63-72. [https://doi.org/10.1016/s0957-4174\(98\)00029-3](https://doi.org/10.1016/s0957-4174(98)00029-3)
- Gerum, P. C. L., Altay, A., & Baykal-Gürsoy, M. (2019). Data-driven predictive maintenance scheduling policies for railways. *Transportation Research Part C: Emerging Technologies*, 107, 137-154. <https://doi.org/10.1016/j.trc.2019.07.020>
- Gharehbaghi, K., McManus, K. J., Hurst, N., Robson, K., Pagliara, F., & Eves, C. (2023). Advanced rail transportation infrastructure as the basis of Improved urban mobility: Research into Sydney as a Smart City. *Australian Planner*, 59(2), 101-116. <https://doi.org/10.1080/07293682.2023.2202867>
- Glorot, X., & Bengio, Y. (2010). Understanding the difficulty of training deep feedforward neural networks. *International Conference on Artificial Intelligence and Statistics*, 249-256.
- González, J. M., Sánchez, N. C., Llop, P. G. M., Pastor, L. A., & Larson, K. (2021). Dynamic V2V power-sharing for collaborative fleets of autonomous vehicles. *2021 IEEE Electrical Power and Energy Conference (EPEC)*, 408-413. <https://doi.org/10.1109/EPEC52095.2021.9621484>
- Google Scholar. (s.f.). <https://scholar.google.es/schhp?hl=es>
- Grande, A. A. (2023). EL APROVECHAMIENTO TURÍSTICO DEL FERROCARRIL CONVENCIONAL COMO VÍA DE IMPULSO TERRITORIAL: EL CASO DE LA LÍNEA DEL DUERO (PORTUGAL) COMO MODELO PARA EL FFCC ARANJUEZ-CUENCA-UTIEL. *Cuadernos de Turismo*, (51), 281-299. <https://doi.org/10.6018/turismo.571631>
- Guo, Q., Liu, L., Xu, W., Gong, Y., Zhang, X., & Jing, W. (2020). An improved faster R-CNN for High-Speed Railway Dropper Detection. *IEEE Access*, 8, 105622-105633. <https://doi.org/10.1109/access.2020.3000506>
- Hák, T., Janoušková, S., & Moldan, B. (2016). Sustainable development goals: a need for relevant indicators. *Ecological Indicators*, 60, 565-573. <https://doi.org/10.1016/j.ecolind.2015.08.003>
- Han, Y., Liu, Z., Lyu, Y., Liu, K., Li, C., & Zhang, W. (2020). Deep learning-based visual ensemble method for high-speed railway catenary Clevis fracture detection. *Neurocomputing*, 396, 556-568. <https://doi.org/10.1016/j.neucom.2018.10.107>
- Havaei, P., & Sandidzadeh, M. A. (2023). Multi-objective train speed profile determination for automatic train operation with conscious Search: A new Optimization Algorithm, A Comprehensive study. *Engineering Applications of Artificial Intelligence*, 119, 105756. <https://doi.org/10.1016/j.engappai.2022.105756>
- He, K., Zhang, X., Ren, S., & Sun, J. (2015). Delving deep into rectifiers: Surpassing Human-Level performance on ImageNet classification. *arXiv (Cornell University)*. <https://doi.org/10.48550/arxiv.1502.01852>

- Hengl, T., Nussbaum, M., Wright, M. N., Heuvelink, G., & Gräler, B. (2018). Random Forest as a generic framework for predictive modeling of spatial and spatio-temporal variables. *PeerJ*, 6, e5518. <https://doi.org/10.7717/peerj.5518>
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- Hoppe, J., Schwinger, F., Haeger, H., Wernz, J., & Jarke, M. (2023). Improving the prediction of passenger numbers in public transit networks by combining Short-Term forecasts with Real-Time occupancy data. *IEEE open journal of intelligent transportation systems*, 4, 153-174. <https://doi.org/10.1109/ojits.2023.3251564>
- Hua, G., Zhu, L., Wu, J., Shen, C., Zhou, L., & Lin, Q. (2020). Blockchain-Based federated learning for intelligent control in heavy haul railway. *IEEE Access*, 8, 176830-176839. <https://doi.org/10.1109/access.2020.3021253>
- Hwang, S., & Kim, J. (2023). A universal activation function for deep learning. *Computers, materials continua*, 75(2), 3553-3569. <https://doi.org/10.32604/cmc.2023.037028>
- INE - Instituto Nacional de Estadística. (s.f.). *INEBase/ Clasificaciones /Relación de municipios, provincias, comunidades y ciudades autónomas con sus códigos / Relación de comunidades y ciudades AUT nomas con sus c digos*. https://www.ine.es/daco/daco42/codmun/cod_ccaa.htm
- Institution, B. S. (2023, 1 de enero). *BS EN 50126-1:2017/PRA1 Railway Applications. The Specification and Demonstration of Reliability, Availability, Maintainability and Safety (RAMS). Generic RAMS Process*.
- Jiang, H., & Gao, L. (2020). Optimizing the rail profile for High-Speed Railways based on artificial neural network and genetic algorithm coupled method. *Sustainability*, 12(2), 658. <https://doi.org/10.3390/su12020658>
- Johnson, N. O. (1937). The Pareto law. *The Review of Economics and Statistics*, 19(1), 20. <https://doi.org/10.2307/1928092>
- Ju, J. X., & Liang, D. X. (2022). Railway Catenary insulator recognition based on improved Faster R-CNN. *Automatic Control and Computer Sciences*, 56(6), 553-563. <https://doi.org/10.3103/s0146411622060074>
- Kaewunruen, S., & Osman, M. H. (2023). Dealing with disruptions in railway track inspection using risk-based machine learning. *Scientific Reports*, 13(1). <https://doi.org/10.1038/s41598-023-28866-9>
- Khabarov, V., & Volegzhanina, I. (2020). Digital Railway as a precondition for industry, science and education Interaction by knowledge management. *IOP Conference Series: Materials Science and Engineering*, 918(1), 012189. <https://doi.org/10.1088/1757-899x/918/1/012189>
- Kimura, K., & Moser, B. R. (2023). Engineering Systems Analysis of Mobility in Odawara City: New transportation services impacts on community engagement. *Systems Engineering*. <https://doi.org/10.1002/sys.21734>
- Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. *arXiv (Cornell University)*. <https://doi.org/10.48550/arxiv.1412.6980>
- Komyakov, A. A., Nikiforov, M. M., Erbes, V. V., Cheremisin, V. T., & Ivanchenko, V. I. (2016). Construction of electricity consumption mathematical models on railway transport used artificial neural network and fuzzy neural network. *2016 IEEE 16th International*

- Conference on Environment and Electrical Engineering (EEEIC)*, 1-4. <https://doi.org/10.1109/EEEIC.2016.7555450>
- Kour, R., Arranz, M. C., Karim, R., Patwardhan, A., Kumar, M., & Granström, R. (2022). A Human-Centric Model for Sustainable Asset Management in Railway: A Case Study. *Sustainability*, 14(2), 936. <https://doi.org/10.3390/su14020936>
- Kruszyna, M. (2022). NOAH as an innovative tool for modeling the use of suburban railways. *Sustainability*, 15(1), 193. <https://doi.org/10.3390/su15010193>
- Kuźnar, M., Lorenc, A., & Kaczor, G. (2021). Pantograph Sliding Strips Failure—Reliability assessment and damage reduction method based on Decision Tree model. *Materials*, 14(19), 5743. <https://doi.org/10.3390/ma14195743>
- Kwatra, D., Rao, K. R., & Bhatnagar, V. (2023). NOVEL ACCESSIBILITY METRICS BASED ON HIERARCHICAL DECOMPOSITION OF TRANSPORT NETWORKS. *Scientific Journal of Silesian University of Technology. Series Transport*, 118, 139-160. <https://doi.org/10.20858/sjsutst.2023.118.10>
- Lecca, T. (2023). Spain says adios to short-haul flights.
- Lee, S., Ko, E., Jang, K., & Kim, S. (2023). Understanding individual-level travel behavior changes due to COVID-19: trip frequency, trip regularity, and trip distance. *Cities*, 135, 104223. <https://doi.org/10.1016/j.cities.2023.104223>
- Leutwiler, F., & Corman, F. (2023). A review of principles and methods to decompose large-scale railway scheduling problems. *EURO Journal on Transportation and Logistics*, 12, 100107. <https://doi.org/10.1016/j.ejtl.2023.100107>
- Li, G., Or, S. W., & Chan, K. W. (2023). Intelligent Energy-Efficient Train Trajectory Optimization Approach based on supervised reinforcement learning for urban rail transits. *IEEE Access*, 11, 31508-31521. <https://doi.org/10.1109/access.2023.3261900>
- Li, H., Parikh, D., He, Q., Qian, B., Li, Z., Fang, D., & Hampapur, A. (2014). Improving rail network Velocity: A machine learning approach to predictive maintenance. *Transportation Research Part C: Emerging Technologies*, 45, 17-26. <https://doi.org/10.1016/j.trc.2014.04.013>
- Lian, H., Wang, X., Sharma, A., & Shah, M. A. (2022). Application and study of artificial intelligence in railway signal interlocking fault. *Informatica*, 46(3). <https://doi.org/10.31449/inf.v46i3.3961>
- Liang, H., Zhang, Y., Yang, P., Wang, L., & Gao, C. (2023). Comparison and analysis of prediction models for locomotive traction energy consumption based on the machine learning. *IEEE Access*, 11, 38502-38513. <https://doi.org/10.1109/access.2023.3268531>
- Litvina, Z. (2023, 28 de septiembre). *The future of door to door mobility is here*. <https://rail-research.europa.eu/news/the-future-of-door-to-door-mobility-is-here/>
- Liu, J., Liu, H., Chakraborty, C., Yu, K., Shao, X., & Ma, Z. (2023). Cascade Learning Embedded vision inspection of rail fastener by using a fault detection IoT vehicle. *IEEE Internet of Things Journal*, 10(4), 3006-3017. <https://doi.org/10.1109/jiot.2021.3126875>
- Liu, Q., & Huang, Z. (2020). Research on intelligent prevention and control of COVID-19 in China's urban rail transit based on artificial intelligence and big data. *Journal of Intelligent and Fuzzy Systems*, 39(6), 9085-9090. <https://doi.org/10.3233/jifs-189307>
- Lorig, F., Persson, J., & Michielsen, A. (2023). Simulating the impact of shared mobility on demand: A study of future transportation systems in Gothenburg, Sweden. *In-*

- ternational Journal of Intelligent Transportation Systems Research*, 21(1), 129-144. <https://doi.org/10.1007/s13177-023-00345-5>
- Lu, S., Wang, J., Jing, G., Qiang, W., & Rad, M. M. (2022). Rail defect classification with deep learning method. *Acta Polytechnica Hungarica*, 19(6), 225-241. <https://doi.org/10.12700/aph.19.6.2022.6.16>
- Luo, J., Wen, C., Peng, Q., Qin, Y., & Huang, P. (2023). Forecasting the Effect of Traffic control strategies in Railway Systems: a hybrid Machine learning method. *Physica A: Statistical Mechanics and its Applications*, 621, 128793. <https://doi.org/10.1016/j.physa.2023.128793>
- Luque, P., Mántaras, D. Á., & Sánchez, L. (2021). Artificial intelligence applied to evaluate emissions and energy consumption in commuter railways: Comparison of liquefied natural gas as an alternative fuel to diesel. *Sustainability*, 13(13), 7112. <https://doi.org/10.3390/su13137112>
- Ma, S., Gao, L., Liu, X., & Lin, J. (2019). Deep Learning for track Quality Evaluation of High-Speed Railway based on Vehicle-Body Vibration Prediction. *IEEE Access*, 7, 185099-185107. <https://doi.org/10.1109/access.2019.2960537>
- Maier, J., Hoermann, H., Goerke, P., & Zierke, O. (2023). Thermal comfort of novel low-momentum ventilation concepts for passengers in long-distance trains. *Indoor and Built Environment*, 32(7), 1319-1334. <https://doi.org/10.1177/1420326x231160038>
- Mao, W., He, J., Tang, J., & Li, Y. (2018). Predicting remaining useful life of rolling bearings based on deep feature representation and long short-term memory neural network. *Advances in Mechanical Engineering*, 10(12), 168781401881718. <https://doi.org/10.1177/1687814018817184>
- Martínez-Llop, P. G., De Dios Sanz Bobi, J., Jiménez, Á. S., & Sánchez, J. G. (2021). Condition-Based maintenance for normal behaviour characterisation of railway Car-Body acceleration applying neural networks. *Sustainability*, 13(21), 12265. <https://doi.org/10.3390/su132112265>
- Martínez-Llop, P. G., De Dios Sanz Bobi, J., & Ortega, M. O. (2023). Time consideration in machine learning models for train comfort prediction using LSTM networks. *Engineering Applications of Artificial Intelligence*, 123, 106303. <https://doi.org/10.1016/j.engappai.2023.106303>
- Martínez-Llop, P. G., De Dios Sanz Bobi, J., & Plaza, A. (2022). Application of neural networks for the prediction of railway bearing failures. *Proceedings of the Institution of Mechanical Engineers, Part F: Journal of Rail and Rapid Transit*, 236(10), 1147-1153. <https://doi.org/10.1177/09544097221084419>
- Marukatat, S. (2022). Tutorial on PCA and approximate PCA and Approximate Kernel PCA. *Artificial Intelligence Review*, 56(6), 5445-5477. <https://doi.org/10.1007/s10462-022-10297-z>
- Mo, X., Cao, C., Li, M., & Wang, D. Z. (2022). Predicting the impact of disruptions to urban rail transit systems. *ACM Transactions on Sensor Networks*, 19(1), 1-17. <https://doi.org/10.1145/3517015>
- Mulongo, N. Y., Mnkandla, E., & Kanakana-Katumba, G. (2021). Artificial Intelligence as Key Driver for Competitiveness in the Railway Industry: Review. *2021 62nd International Scientific Conference on Information Technology and Management Science of Riga Technical University (ITMS)*, 1-6. <https://doi.org/10.1109/ITMS52826.2021.9615314>

- Munoko, I., Brown-Liburd, H. L., & Vasarhelyi, M. A. (2020). The ethical implications of using artificial intelligence in auditing. *Journal of Business Ethics*, 167(2), 209-234. <https://doi.org/10.1007/s10551-019-04407-1>
- Ng, M. T. M., Schofer, J. L., & Mahmassani, H. S. (2023). How well did U.S. rail and intermodal freight respond to the COVID-19 pandemic versus the Great Recession? *Transportation Research Record*, 2677(4), 597-610. <https://doi.org/10.1177/03611981221150444>
- Nickdoost, N., Jalloul, H., Choi, J., & Smith, D. B. (2023). Identification and prioritization of multidimensional resilience factors for incorporation in coastal state transportation infrastructure planning. *Natural Hazards*. <https://doi.org/10.1007/s11069-023-06251-z>
- Niu, Y., Li, X., Zhang, J., Deng, X., & Chang, Y. (2023). Efficiency of railway Transport: A comparative analysis for 16 countries. *Transport Policy*, 141, 42-53. <https://doi.org/10.1016/j.tranpol.2023.07.007>
- Nkesah, S. K. (2023). Making road freight transport More Sustainable: Insights from a Systematic Literature review. *Transportation Research Interdisciplinary Perspectives*, 22, 100967. <https://doi.org/10.1016/j.trip.2023.100967>
- Odiijk, M. J. M., Asadi, M., Ulak, M. B., & Geurs, K. (2023). The interactions between accessibility and crash risk from a social equity perspective: a case study at the Rotterdam-The Hague Metropolitan Region. *Journal of Safety Research*, 87, 176-186. <https://doi.org/10.1016/j.jsr.2023.09.015>
- Oh, K. T., Yoo, M., Jin, N., Ko, J., Seo, J., Joo, H., & Ko, M. (2022). A review of deep learning applications for railway safety. *Applied sciences*, 12(20), 10572. <https://doi.org/10.3390/app122010572>
- Oliver Wyman. (s.f.). *Mobility 2040: The quest for smart Mobility*. <https://www.oliverwyman.com/our-expertise/insights/2018/aug/mobility-2040--the-quest-for-smart-mobility.html>
- Open Data Movilidad | Ministerio de Transportes, Movilidad y Agenda Urbana. (s.f.-a). <https://www.mitma.gob.es/ministerio/proyectos-singulares/estudios-de-movilidad-con-big-data/opendata-movilidad>
- Open Data Movilidad | Ministerio de Transportes, Movilidad y Agenda Urbana. (s.f.-b). <https://www.mitma.gob.es/ministerio/proyectos-singulares/estudios-de-movilidad-con-big-data/opendata-movilidad>
- Pang, S., & Chen, M. (2023). Optimize railway crew scheduling by using modified bacterial foraging algorithm. *Computers Industrial Engineering*, 180, 109218. <https://doi.org/10.1016/j.cie.2023.109218>
- Pănoiu, M., Pănoiu, C., Mezinescu, S., Militaru, G., & Baci, I. (2023). Machine learning techniques applied to the harmonic analysis of railway power supply. *Mathematics*, 11(6), 1381. <https://doi.org/10.3390/math11061381>
- Pappalardo, L., Manley, E., Sekara, V., & Alessandretti, L. (2023). Future directions in human mobility science. *Nature Computational Science*, 3(7), 588-600. <https://doi.org/10.1038/s43588-023-00469-4>
- Pappaterra, M. J., Flammini, F., Vittorini, V., & Bešinović, N. (2021). A Systematic Review of Artificial Intelligence public datasets for railway applications. *Infrastructures*, 6(10), 136. <https://doi.org/10.3390/infrastructures6100136>
- Parhi, R., & Nowak, R. (2020). The role of neural network activation functions. *IEEE Signal Processing Letters*, 27, 1779-1783. <https://doi.org/10.1109/lsp.2020.3027517>


- Patwardhan, A., Thaduri, A., & Karim, R. (2021). Distributed ledger for cybersecurity: Issues and challenges in railways. *Sustainability*, 13(18), 10176. <https://doi.org/10.3390/su131810176>
- Pineda-Jaramillo, J., & Viti, F. (2023). MLOPs in freight rail operations. *Engineering Applications of Artificial Intelligence*, 123, 106222. <https://doi.org/10.1016/j.engappai.2023.106222>
- Pires, A., Mendes, G., Santos, G. F. M. D., Dias, A. P. C., & Santos, A. A. D. (2021). Indirect identification of wheel rail contact forces of an instrumented heavy haul railway vehicle using machine learning. *Mechanical Systems and Signal Processing*, 160, 107806. <https://doi.org/10.1016/j.ymsp.2021.107806>
- Portal del Observatorio del Transporte y la Logística en España, OTLE. (s.f.). <https://observatoriotransporte.mitma.es/>
- Pourrahmani, H., Yavarinasab, A., Monazzah, A. M. H., & Van Herle, J. (2023). A review of the security vulnerabilities and countermeasures in the Internet of Things Solutions: A Bright Future for the Blockchain. *Internet of Things*, 23, 100888. <https://doi.org/10.1016/j.iot.2023.100888>
- Qin, H., Zaman, A., & Liu, X. (2023). Artificial intelligence-aided intelligent obstacle and trespasser detection based on locomotive-mounted forward-facing camera data. *Proceedings of the Institution of Mechanical Engineers, Part F: Journal of Rail and Rapid Transit*, 237(9), 1230-1241. <https://doi.org/10.1177/09544097231156312>
- Reiter, V., Voltes-Dorta, A., & Suau-Sánchez, P. (2022). The substitution of short-haul flights with rail services in German air travel markets: A quantitative analysis. *Case Studies on Transport Policy*, 10(4), 2025-2043. <https://doi.org/10.1016/j.cstp.2022.09.001>
- Revista Digital - Efecto de la fiabilidad sobre el coste del mantenimiento. Determinación del intervalo de intervención que proporciona el mínimo coste de mantenimiento. (s.f.).
- Rodríguez-Rueda, P. J., & Turias, I. J. (2017). Una comparativa entre redes neuronales artificiales y métodos clásicos para la predicción de la movilidad entre zonas de transporte. aplicación práctica en el campo de Gibraltar, España. *Dyna-colombia*, 84(200), 209-216. <https://doi.org/10.15446/dyna.v84n200.56571>
- Rojas, R. (1996). Statistics and Neural Networks. En *Neural Networks: A Systematic Introduction* (pp. 227-261). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-642-61068-4_9
- Rudachenko, O., Svitlychna, V., Krasnokutskyi, Y. S., & Pyskun, L. (2023). FORECASTING INVESTMENT ACTIVITIES OF RAIL TRANSPORT ENTERPRISES USING TREND MODELS. *Finansovo-kreditna diâlnist: problemi teorii ta praktiki*, 3(50), 202-212. <https://doi.org/10.55643/fcaptop.3.50.2023.4064>
- Ruder, S. (2016). An overview of gradient descent optimization algorithms. *arXiv (Cornell University)*.
- Sadeghi, J., & Askarinejad, H. (2012). Application of neural networks in evaluation of railway track quality Condition. *Journal of Mechanical Science and Technology*, 26(1), 113-122. <https://doi.org/10.1007/s12206-011-1016-5>
- Saeed, M., Briz, F., Guerrero, J. M., Larrazabal, I., Ortega, D., López, V. S. I., & Valera, J. J. (2023). Onboard Energy Storage Systems for railway: Present and Trends. *IEEE open journal of industry applications*, 4, 238-259. <https://doi.org/10.1109/ojia.2023.3293059>

- Santos González-Llanos, J. (2023, julio). *Estado del arte de la inteligencia artificial en el sector ferroviario poniendo en común fabricante, operadora e infraestructura* [No Publicado].
- Sepanta, F., & O'Brien, W. (2023). Review and exploration of relationships between domains impacted by telework: A glimpse into the energy and sustainability considerations, COVID-19 implications, and future research. *Renewable Sustainable Energy Reviews*, 183, 113464. <https://doi.org/10.1016/j.rser.2023.113464>
- Seraco, I. P., & Neto, H. X. R. (2023). Contribution to railway track maintenance planning from the analysis of dynamic movements of trains. *Civil Engineering Journal*, 9(2), 254-272. <https://doi.org/10.28991/cej-2023-09-02-02>
- Shen, Y., Zhao, J., De Abreu E Silva, J., & Martínez, L. (2017). From accessibility improvement to land development: A comparative study on the impacts of Madrid-Seville high-speed rail. *Transportation Letters: The International Journal of Transportation Research*, 9(4), 187-201. <https://doi.org/10.1080/19427867.2017.1286771>
- Sheng, J., Cai, X., Li, Q., Wu, C., Ai, B., Wang, Y., Kadoch, M., & Yu, P. (2022). Space-Air-Ground Integrated Network Development and Applications in High-Speed Railways: a survey. *IEEE Transactions on Intelligent Transportation Systems*, 23(8), 10066-10085. <https://doi.org/10.1109/tits.2021.3118557>
- Shi, Z., & Chehade, A. (2021). A dual-LSTM framework combining change point detection and remaining useful life prediction. *Reliability Engineering System Safety*, 205, 107257. <https://doi.org/10.1016/j.ress.2020.107257>
- Shu, J., Zhang, Z., González, I., & Karoumi, R. (2013). The application of a damage detection method using artificial neural network and train-induced vibrations on a simplified railway bridge model. *Engineering Structures*, 52, 408-421. <https://doi.org/10.1016/j.engstruct.2013.02.031>
- Sikora, P., Malina, L., Kiac, M., Martinásek, Z., Říha, K., Přinosil, J., Jirik, L., & Srivastava, G. (2021). Artificial Intelligence-Based Surveillance System for railway crossing traffic. *IEEE Sensors Journal*, 21(14), 15515-15526. <https://doi.org/10.1109/jsen.2020.3031861>
- Silva, P., Ribeiro, D., Mendes, J., Seabra, E., & Postolache, O. (2023). Railways Passengers Comfort Evaluation Through Motion Parameters: A Systematic review. *Machines*, 11(4), 465. <https://doi.org/10.3390/machines11040465>
- Singhal, V., Jain, S. P., Anand, D., Singh, A., Verma, S., K., Rodrigues, J. J. P. C., Jhanjhi, N. Z., Ghosh, U., Jo, O., & Iwendi, C. (2020). Artificial Intelligence Enabled Road Vehicle-Train Collision Risk Assessment Framework for Unmanned railway level crossings. *IEEE Access*, 8, 113790-113806. <https://doi.org/10.1109/access.2020.3002416>
- Siregar, I., & Zulkarnain. (2022). The Relationship between conflict and Social Change in the perspective of Expert Theory: a literature review. *International Journal of Arts and Humanities Studies*, 2(1), 09-16. <https://doi.org/10.32996/bjahs.2022.2.1.2>
- Sresakoolchai, J., Hamarat, M., & Kaewunruen, S. (2023). Automated machine learning recognition to diagnose flood resilience of railway switches and crossings. *Scientific Reports*, 13(1). <https://doi.org/10.1038/s41598-023-29292-7>
- Sresakoolchai, J., & Kaewunruen, S. (2021). Integration of building information modeling and machine learning for railway defect localization. *IEEE Access*, 9, 166039-166047. <https://doi.org/10.1109/access.2021.3135451>

- Stenström, C., Norrbin, P., Parida, A., & Kumar, U. (2015). Preventive and Corrective maintenance – cost comparison and cost–benefit analysis. *Structure and Infrastructure Engineering*, 12(5), 603–617. <https://doi.org/10.1080/15732479.2015.1032983>
- Stoian, C., Caraiiani, C., Anica-Popa, I. F., Dascălu, C., & Lungu, C. I. (2022). Telework Systematic Model Design for the future of work. *Sustainability*, 14(12), 7146. <https://doi.org/10.3390/su14127146>
- Sutherland, J., Bélec, J., Sheikh, A., Chepelev, L. L., Althobaity, W., Chow, B. J., Mitsouras, D., Christensen, A., Rybicki, F. J., & La Russa, D. (2018). Applying modern virtual and augmented reality technologies to medical images and models. *Journal of Digital Imaging*, 32(1), 38–53. <https://doi.org/10.1007/s10278-018-0122-7>
- Taherdoost, H. (2022). An overview of trends in information systems: Emerging technologies that transform the information technology industry. *Cloud computing and data science*, 1–16. <https://doi.org/10.37256/ccds.4120231653>
- Tang, Y., Wang, Y., & Qian, Y. (2023). Railroad crossing Surveillance and Foreground Extraction network: Weakly Supervised Artificial-Intelligence Approach. *Transportation Research Record*, 2677(9), 525–538. <https://doi.org/10.1177/03611981231159406>
- Tao, L., Bie, Z., Jiang, L., Chen, C., Li, G., & Xie, H. (2023). Robust hierarchical scheduling approach to coordinate wind power penetrated transmission system and LNG railway transportation. *IEEE Transactions on Smart Grid*, 14(2), 996–1010. <https://doi.org/10.1109/tsg.2022.3203155>
- The International Association of Public Transport | UITP. (s.f.).
- Tubis, A., & Rohman, J. N. (2023). Intelligent Warehouse in Industry 4.0—Systematic Literature review. *Sensors*, 23(8), 4105. <https://doi.org/10.3390/s23084105>
- Uhl, T., Mendrok, K., & Chudzikiewicz, A. (2010). Rail Track and Rail Vehicle Intelligent Monitoring System. *Archives of Transport*, 22(4). <https://doi.org/10.2478/v10174-010-0030-1>
- UNE-EN 12299:2010 Aplicaciones ferroviarias. Comodidad de viaj... (s.f.). <https://www.une.org/encuentra-tu-norma/busca-tu-norma/norma?c=N0045231>
- UNE-EN 14363:2017 Aplicaciones ferroviarias. Ensayos y simulac... (s.f.). <https://www.une.org/encuentra-tu-norma/busca-tu-norma/norma?c=N0058126>
- Urda, P., Aceituno, J. F., Muñoz, S., & Escalona, J. L. (2020). Artificial neural networks applied to the measurement of lateral wheel-rail contact force: a comparison with a harmonic cancellation method. *Mechanism and Machine Theory*, 153, 103968. <https://doi.org/10.1016/j.mechmachtheory.2020.103968>
- Valenzuela, V. G., & Holl, A. (2023). Growth and Decline in Rural Spain: an exploratory analysis. *European Planning Studies*, 1–24. <https://doi.org/10.1080/09654313.2023.2179390>
- Verma, P., Kumari, T., & Raghubanshi, A. S. (2021). Energy Emissions, Consumption and Impact of Urban Households: A review. *Renewable Sustainable Energy Reviews*, 147, 111210. <https://doi.org/10.1016/j.rser.2021.111210>
- Wallimann, H., Blättler, K., & Von Arx, W. (2023). Do price reductions attract customers in urban public transport? A synthetic control approach. *Transportation Research Part A: Policy and Practice*, 173, 103700. <https://doi.org/10.1016/j.tra.2023.103700>
- Wan, T. H., Tsang, C. W., Hui, K., & Chung, E. (2023). Anomaly detection of train wheels utilizing short-time fourier transform and unsupervised learning algorithms. *Enginee-*

- ring Applications of Artificial Intelligence*, 122, 106037. <https://doi.org/10.1016/j.engappai.2023.106037>
- Wang, L., Yu, S., Chen, D., Li, W., Chu, J., & Fan, H. (2023). Effects of aircraft tray table height and neck posture on passenger comfort: A study of the Economy Class Cabin. *Work-a Journal of Prevention Assessment Rehabilitation*, 75(1), 287-302. <https://doi.org/10.3233/wor-220043>
- Wang, T., Yang, F., & Tsui, K. (2020). Real-Time detection of railway track component via One-Stage deep learning networks. *Sensors*, 20(15), 4325. <https://doi.org/10.3390/s20154325>
- Wang, Z. (2020). Design of Railway Accident Analysis System Based on Artificial Intelligence. *2020 3rd International Conference on Smart BlockChain (SmartBlock)*, 45-50. <https://doi.org/10.1109/SmartBlock52591.2020.00016>
- Web of Science. (s.f.). <https://www.webofscience.com/wos/woscc/basic-search>
- Well-to-wheel (wake/wing) GHG Intensity of Motorised Passenger Transport Modes – Charts – Data Statistics - IEA. (s.f.). <https://www.iea.org/data-and-statistics/charts/well-to-wheel-wake-wing-ghg-intensity-of-motorised-passenger-transport-modes-2>
- Xu, J., & Ai, B. (2021). Artificial Intelligence Empowered Power Allocation for Smart Railway. *IEEE Communications Magazine*, 59(2), 28-33. <https://doi.org/10.1109/MCOM.001.2000634>
- Yangping, W., Shumei, H., Jingyu, Y., Jianwu, D., & Zhanping, Z. (2022). Improved YOLOv4 method for detecting ground objects in remote sensing images along railway lines. *Spectroscopy and Spectral Analysis*, 42(10), 3275-3282.
- Yin, J., & Zhao, W. (2016). Fault diagnosis network design for vehicle on-board equipments of high-speed railway: A deep learning approach. *Engineering Applications of Artificial Intelligence*, 56, 250-259. <https://doi.org/10.1016/j.engappai.2016.10.002>
- Younan, M., Elhoseny, M., Ali, A. A., & Houssein, E. H. (2021). Quantum Chain of Things (QCoT): A New Paradigm for Integrating Quantum Computing, Blockchain, and Internet of Things. *2021 17th International Computer Engineering Conference (ICENCO)*, 101-106. <https://doi.org/10.1109/ICENCO49852.2021.9698947>
- Zhang, H., Xue, H., Yan, W., Jiang, Z., & Zhu, S. (2022). A machine learning-based approach for product maintenance prediction with reliability information conversion. *Autonomous Intelligent Systems*, 2(1). <https://doi.org/10.1007/s43684-022-00033-3>
- Zhang, J., & Zhang, J. (2023). Artificial Intelligence Applied on Traffic Planning and Management for Rail Transport: A Review and Perspective. *Discrete Dynamics in Nature and Society*, 2023, 1-17. <https://doi.org/10.1155/2023/1832501>
- Židová, Z., & Zitrický, V. (2023). The impact of the use of technology in international rail freight transport on transport processes. *Promet-traffic Transportation*, 35(2), 243-254. <https://doi.org/10.7307/ptt.v35i2.123>

Anexos



Time consideration in machine learning models for train comfort prediction using LSTM networks

Pablo Garrido Martínez-Llop^{*}, Juan de Dios Sanz Bobi, Manuel Olmedo Ortega

Department of Applied Mathematics, Universidad Politécnica de Madrid, Spain

ARTICLE INFO

Keywords:

Time independence model
Deep learning
Predictive maintenance
Railway dynamics
Car body accelerations
Comfort degradation
Failure diagnosis
Anomaly detection

ABSTRACT

Safety and passengers' comfort affect directly the reliability and availability of trains. Therefore, appropriate monitoring of the variables influencing those two concepts is mandatory for good operation and maintenance costs reduction. Moreover, operators and rail manufacturers are evolving to a condition-based maintenance strategy (CBM). For this purpose, machine learning is being used to predict early main component's failures, avoiding a loss of reliability or availability during commercial operation. From the passengers' point of view, punctuality and comfortability are two of the most relevant factors when evaluating a railway transport service. Comfort is mainly based on the availability of all services in the train, but it is also related to the accelerations received through the car body to the passengers. More precisely, the lateral car body acceleration (Ayc variable in this paper) is a key variable related to comfort perception and it is therefore important to be monitored and controlled. Rolling, suspension, and damping elements must be kept in perfect conditions during operation to achieve a smooth train movement. In this paper, an optimized model based on Long Short Term Memory networks (LSTM) is designed and trained to predict lateral car body accelerations using only the train accelerometers and with no additional sensing for this specific experiment. This model will be compared with artificial neural networks (ANN) models to evaluate the relevance of time dependency for this purpose. The optimal time frame to group data is a key characteristic of the neural network training process and is also determined in this paper. The model is trained with data corresponding to the correct dynamic behavior of the train. To test the reliability of this method, a real case of excessive train movement is tested. In these situations, an alert could be sent to the operator or the maintainer for a not-programmed maintenance inspection at the depot (predictive maintenance), avoiding future passenger complaints for the loss of comfort or, in extreme cases, speed limitations due to safety reasons for excessive accelerations. The main contributions of this work are the following:

- A LSTM-based neural network, predicting lateral car body accelerations achieving better results than a plain ANN for this dataset: 0.0335 m/s² MAE and a 12% gain on extreme axes.
- An optimization of the time frame to group the measurements in this algorithm that is considering as an input the time variable: 5 s.
- A real use case of the model in which monitoring the deviation would have helped to take an early maintenance adjustment on the suspension or damping elements to prevent the loss of comfort.
- The p-value used to reduce the uncertainty of the results obtained in the real use case is reaching over 0.95 in the coaches with good dynamic behavior and less than 0.15 in the coaches where a dynamic problem related to comfort loss is detected.

1. Introduction

Comfort is a key aspect that influences the choice of a transportation mode. Sustainability forums such as the United Nations Agenda 2030 suggest that a shift to railway transportation can have a significant impact on reducing emissions. Improving comfort in railways is therefore

on the roadmap of railway manufacturers and train operators. Vibrational comfort, along with thermal comfort, noise, and other parameters are relevant to the passenger's use of experience when traveling by train. It depends on the dynamic behavior of the train so it is always monitored as a safety parameter. It is particularly interesting to implement models that can detect component degradation and comfort loss.

^{*} Corresponding author.

E-mail addresses: pablo.garrido@upm.es (P. Garrido Martínez-Llop), juandedios.sanz@upm.es (J.d.D. Sanz Bobi), m.olmedo@alumnos.upm.es (M. Olmedo Ortega).

<https://doi.org/10.1016/j.engappai.2023.106303>

Received 15 August 2022; Received in revised form 31 March 2023; Accepted 6 April 2023

Available online 27 April 2023

0952-1976/© 2023 The Authors. Published by Elsevier Ltd. This is an open access article under the CC BY-NC-ND license

(<http://creativecommons.org/licenses/by-nc-nd/4.0/>).

The industry is turning towards to Condition-Based-Maintenance (CBM) practices. This involves monitoring the behavior of the components and installing IoT sensors in some principal components. Acceleration measures are taken by the train sensors at several different points, allowing continuous monitoring and the development of failure detection models.

Machine learning techniques can be used in predictive maintenance to characterize the correct behavior of a component. Car body accelerations have already been used to assess the condition of tracks and detect irregularities as in [Xiukun et al. \(2016\)](#) and [Mai et al. \(2017\)](#). This work demonstrates the effectiveness of these models. As the component suffers from degradation, the differences between the machine learning prediction and the real measures tend to increase, evidencing a possible anomaly. This paper follows this approach to try to improve models already in the literature, such as an Artificial Neural Network (ANN) designed to fulfill this purpose ([Martínez-Llop et al., 2021](#)). However, this neural network architecture does not take into account time dependency. Compared to [Huang and Kaewunruen \(2022\)](#), this paper uses the existing accelerometer data of a high-speed train instead of smartphone measurements, resulting in more information on the whole train composition. The technique presented in [Huang and Kaewunruen \(2022\)](#) uses a Convolutional Neural Network as a feature extractor followed by a Support Vector Regressor (SVR). The feature extractor delivers time-dependent features. This paper uses only a Recurrent Neural Network (RNN) with Long Short Term Memory cells (LSTM) to tackle this problem, resulting in a lighter model, less resource-consuming. The resulting model will be tested in a real case scenario to detect early a loss of comfort noted by a passenger. The results of this test will be compared to the ANN model on the same dataset.

2. Background

Sustainability and reduction of accidents rate stand at the heart of industrial research and plans for the future, having a direct impact on society. The agenda 2030 contains a specific action plan for mitigating its consequences and correcting the actual tendency for a more sustainable and safe future ([IPCC, 2007](#)). Both fields are closely linked to regional and long-distance transport and take part in the government's agenda across all European countries.

Sustainability is being treated through the reduction of the emissions of greenhouse gases (measured with their CO₂eq) and other pollutants. This emission reduction leads to increasing the energy efficiency in urban and long-distance transport, reducing fossil fuel consumption, and investing in new green technologies such as hydrogen fuel cells ([Hoffrichter et al., 2016](#)) and other alternative transport solutions ([Hoogma et al., 2002](#)).

On the other hand, safety has been deeply studied in the last decades ([Jones-Lee and Jones-Lee, 1990](#)) and further technical optimization is difficult to achieve in the trains or the infrastructure. In this sense, the actual objective in different countries, aligned with the sustainable transport concept, is to focus on shifting cargo and people transport from the roads to the rail, reducing the traffic accident rates, increasing safety, and reducing the transport sector emissions to the atmosphere ([Heinold and Meisel, 2018](#)).

Moreover, the traditional trip concept, which was conceived in the past as a necessary service to place people or goods from one geographic point to another, is also changing to an experience concept from the passenger's point of view. Additional services are being demanded by users over the last decades: Wi-Fi availability, personalized food, and drink orders, entertainment platforms integrated, door-to-door service, etc. ([Ai et al., 2015](#)).

Comfort is one of the most valued aspects by passengers when choosing a transportation mode, along with punctuality, door-to-door time, price, etc. Several studies link vibrations and dynamic behavior to passenger comfort, such as [Graa et al. \(2015\)](#), [Siefert et al. \(2008\)](#)

and [Zhai et al. \(2015\)](#). Added to that, the monitorization of vibration is also used to detect component failures, such as problems with dampers or suspension. It is therefore beneficial to monitor vibrations as they can be used to improve both passenger experience and incoming train failure detection. In railway dynamics, this comfort results in smooth train behavior, avoiding abrupt movements, and controlling the lateral car body accelerations, which is the most relevant variable for defining the train dynamic behavior felt by the passengers.

Different comfort parameters are presented in the standards ([DIN EN 12299:2009-08, 2009](#)), being the medium and continuous comfort closely related to passenger comfort. On the other hand, safety limits for wheelset or car body excessive accelerations are determined by triggering programmed alarms through the train diagnosis. Safety cases are then under control, but the comfort loss starts much before these alarms are activated, and there are no continuous indicators that could detect the degradation of comfort at an early stage. Comfort degradation is not monitored due to the standards. Moreover, the initial certification test for quality ride classification is not accurate enough to determine the real comfortability of the train. Many variables affect the dynamic behavior: maintainability of the damping system and suspension system, the infrastructure, the coupling system between the coaches, etc. Those are not static variables, through the life of the train, subsystems tend to degrade.

Therefore, the dynamic behavior should be specially monitored to maintain the highest degree of comfort. Many sensors and electronics are used to supervise railway dynamics ([Ngigi et al., 2012](#)). These sensors are installed in the wheelset and in the car body of the train. The wheelset accelerations provide information about the first contact between the infrastructure and the rolling stock: defects in the infrastructure could be detected but also in the wheelset such as guiding, wheelset convergence, or balance defect. A lack of quality in this first interaction between the infrastructure and the wheels of the train, which also is covered by the primary suspension, will cause serious vibrations in the car body. On the other hand, the car body accelerations reflect the real vibrations that the passengers are perceiving in the train after the filter is applied by the secondary suspension.

Comfort monitorization is then important in a double sense: detecting defects in the infrastructure or anomalies in damping or suspension components in the train, and also for detecting at an early stage the initial process of comfort degradation. This last idea is directly related to the main goal of this paper, which is the development of a continuous key indicator of the train comfort perceived by the passengers. This will not only prevent any potential component failures on the damping or suspension system as mentioned before but also will provide differential value to passengers and the state-of-the-art, progressing in the user experience idea and also in the industry and maintenance 4.0 concept.

An optimized car body acceleration predictive model is an excellent contribution to the early detection of comfort degradation or any failure in the damping system that could cause speed limitation or cancelled train services due to safety reasons. In these situations, operators or manufacturers are incurring high penalties for the delay produced, and the company's corporate image is damaged. In addition to this, a Condition Based Maintenance (CBM) strategy allows good resource planning and optimization at the maintenance depots by removing unnecessary maintenance actions. A good implementation of predictive maintenance is surely causing clear economic benefits ([Farahani et al., 2020](#); [Daily and Jeff, 2017](#)).

Many papers are studying the early failure detection of components in different industrial sectors ([Daily and Jeff, 2017](#); [Roberto et al., 2022](#)), and also in the railway sector for predictive maintenance applications ([Farahani et al., 2020](#); [Ting et al., 2023](#)). In the paper ([Karakasis et al., 2005](#)) an alternative way of calculating one of the variables specified by the standard for the calculation of comfort is proposed. The train is equipped with sensors in a particular way to carry out this specific experiment. Ride comfort is analyzed in other papers with vertical accelerations ([Wu and Qiu, 2020](#)) in a specific component of the train

such as the seats or taking into account the influence of other elements related to the suspension system (Dižo. et al., 2021). However, the global comfort is not only related to the seats, the global input comes from the lateral acceleration. For all these applications there are also some investigations in which machine learning is used (Rojas, 1996). In this paper, the global comfort in one coach is evaluated through the lateral car body acceleration (Ayc) monitored, which is demonstrated to be the most relevant variable for passengers' comfort, and using the current accelerometers of the train and with no additional sensorization for this experiment. This means that a direct implementation in the whole fleet is possible and no investment is needed for this comfort monitorization.

2.1. Related work

The use of machine learning in predictive maintenance tasks or early failure detection has increased over the last few years. There are many other applications of artificial intelligence in the railway sector (Ma et al., 2020; Guo et al., 2022; Zhang et al., 2018). Predictive maintenance allows operators to optimize the train stops and reduce the time and cost impact on the train operation. Many studies use Machine Learning to detect fault diagnosis (Ye et al., 2022; Davari et al., 2021; El Said et al., 2016; de Pater and Mitici, 2023; Jiateng and Wentian, 2016) or calculate the remaining useful life of components (RUL) in the railway sector (Hu and Dai, 2022) and in other means of transport (Ersöz et al., 2022). All these studies are related to the predictive maintenance of components. Some other papers focus on train comfort (quality ride comfort), treating it as a qualitative characteristic appreciated by passengers, such as Beard and Griffin (2013) and Han (2013). Most of them have applications in infrastructure problem detection, such as track condition monitoring or wheelset fault diagnosis based on the interaction track wheelset-track (La Paglia et al., 2023; Men et al., 2022; Celiński et al., 2022), but none of them are related to the final comfort perception by the passenger. One paper mixes LSTM (the specific algorithm used in this paper) and train accelerations that could influence the passenger's comfort on the train, but its purpose is focused on the bogie fault diagnosis. A use of LSTM cells in lateral vibration monitoring for comfort loss detection has been developed for bus drivers as explained in Zeng et al. (2023).

Other current research is the RUL calculations or fault diagnosis, contributing the railway operation optimization. However, there is a lack of studies focusing on improving ride quality (passenger comfort) using LSTM or other relevant time-considering algorithms. Research in terms of passenger comfort is done with descriptive statistic data analysis or signal analysis, leaving unexplored deep learning or modern artificial intelligence algorithms.

The contribution of this paper is therefore detecting quantitatively the loss of comfort in the train using a machine learning algorithm that considers the time influence (the order of the samples) compared to Martínez-Llop et al. (2021), which does not consider the time variable, and with the current sensorization of the existing trains.

3. Theoretical base and methodology

Artificial Neural Networks (ANN) are one of the most used machine learning techniques due to their versatility, scalability, and performance in solving different regression or classification problems. ANN is inspired by biological neurons, and the ability of our brains to compute complex calculations through the interaction between simple neuron synapses. In the algorithm, the neurons, which are called perceptrons, are organized in huge networks, often composed of stacked layers. (Rojas, 1996).

The inputs for the first perceptron are composed of the initial data collected for the prediction problem. The inputs for the rest of the perceptrons are composed of the outputs of the previous layer. The input features are transformed by a linear operation followed by a

non-linear operation, called the activation function (ϕ). Different mathematical functions are commonly used for the non-linear calculation and it should be determined in each problem for better optimization and convergence of the model. In this paper, the hyperbolic tangent is used (Sibi et al., 2013). The output of a perceptron is expressed by:

$$h_{w,b}(X) = \phi(XW + b) \quad (1)$$

where X is the matrix of input features, W contains the connection weights and b is the bias vector. A bias vector is essential because without it no layer would be able to produce an output for the next layer that differs from 0 if the feature values are 0, and also contributes to a better performance of the problem.

Neural networks need to be trained, with the main purpose of reducing a cost function defined, that evaluates the error rates of the prediction made by the algorithm. This process reinforces the connection between neurons reducing error in terms of compensating neurons' weight to obtain the minimum possible error. The backpropagation algorithm, which uses a gradient descent method is used to compute the cost function gradients and update the neuron's weights, minimizing the cost function (Du et al., 2019). ANN is not considering time dependence or the order of the inputs. The main purpose is to relate the different values of the measured variables sample by sample. But the order and in consequence the time dependence is not considered. To solve this issue, Recurrent Neural Networks are used for the time variable consideration, introducing memory to the neurons. The neuron output at a time $t-1$ will be fed again to the network at a time t alongside the input X_t (Dyer et al., 2016) (see Fig. 1).

However, the performance of recurrent networks is not optimized in long-time dependencies because of vanishing or exploding gradient issues. The LSTM cell gated structure allows handling time dependencies up to 1000 steps considering short-term dependencies (Zaremba et al., 2014). In this paper, an LSTM model will be developed for the prediction of the normal lateral car body acceleration behavior of a train.

This cell is composed of three different gates: the forget gate, the input gate, and the output gate. The forget gate decides how much of the previous state of the cell is used. It could be interpreted as a reset button. The input gate decides how much of the information needs to be introduced in the cell state, like a switching functionality. The output gate reads the cell state C_{t-1} and combine it with the information received from X_t and h_{t-1} to produce the output h_t as it is shown in Fig. 2:

4. Data/model preparation

In this paper, existing data from a specific high-speed train model has been used. A dataset of one year is considered representative of this study as enough samples are registered for model optimization and all particular situations due to the external conditions are contemplated in this period. The dataset corresponds to the year 2017. The selected type of train operates in lines at a maximum speed of 300 km/h. Madrid-Valencia is an example of these lines. This trainset is composed by two powerheads and 12 passenger coaches but includes 13 axles because the 6th coach has a double axis. The maximum weight per axle is 22,5 t and the distance between them is 13,3 m.

Many variables are registered in a high-speed train. Some of them are continuous signals such as temperatures or accelerations and others are state variables such as the status of the pantograph (up or down). The dataset used in this study contains the following continuous variables recorded in real-time: train speed (v), exterior temperature (Text), bearing temperatures (T0-T3 as there are 4 bearing temperature sensors per axle), braking pressure (p), lateral wheelset acceleration (Ayr), lateral car body acceleration (Ayc) and vertical car body acceleration (Azc) of all the 12 coaches of the trainset.

As CBM relies on data availability, the train is equipped with sensors. Many variables are measured, for safety reasons, maintenance reasons, or diagnosis reasons.




Fig. 1. RNN structure (Anon, 2017).




Fig. 2. Structure of LSTM cell gated (Varsamopoulos et al., 2018).




Fig. 3. A high-speed train layout was used for this study.

Measurement sensor errors have been removed from the dataset to obtain a more robust optimized predictive model. Samples with a non-coherent timestamp have also been removed since the timestamp plays a key role in the time-sliding window algorithm to assure that samples are consecutive. All samples considered in the dataset correspond to a good behavior of the train car body accelerations. It is a common technique in anomaly detection to predict the normal behavior of a component and enable an alarm when the differences between the predicted behavior and the real one starts increasing.

The sensors architecture is composed of an accelerometer, followed by a band-pass filter and a U/I Converter. The measurements are then

registered using an onboard acquisition system and stocked in memory units.

To feed the LSTM neural network, it is important to group data samples. In this model a sample is composed by the measurements of the sensors over t seconds, forming a matrix X whose shape is $t \times s$. Those matrices are concatenated to form an array, which is the input of the neural network. To form those matrices, a time-sliding window algorithm is used. As several samples were eliminated during the data cleaning process, a timestamp check is considered essential to ensure that the samples are time consecutive. The appropriate choice of the time window considered to group the data is studied in this paper and determined. The timestamp check can slow down the sliding window




Fig. 4. Data distribution.

Table 1
Structure of model 1.

Layer (type)	Output shape
LSTM cells	(,64)
Dense	(,1)

algorithm as it requires an additional operation. If the data gathered by the train is reliable and consecutive, this step can be avoided to speed up the process.

Regarding the creation of the train, test, and validation data set, it is important to highlight that two consecutive samples are not always changing every second recorded because the acceleration values are statistical values calculated as the root mean square values over 5-second intervals of frequency-weighted accelerations according to the norm EN12299 (DIN EN 12299:2009-08, 2009). For this reason, a random separation of train and test splits can lead to data leakage and therefore to obtain false results. A solution for this issue is to make a monthly basis split, assigning February and September to the test dataset, April to the validation dataset, and the other months to the training dataset. Data distribution in the train, test, and validation test is presented in Fig. 4. In this figure, it is demonstrated that, although the samples correspond to different months, dynamic behavior is quite similar, and no clear differences are appreciated in the data due to this temporal split.

5. Model definition

As the aim of this study is to determine if the LSTM architecture presents an advantage compared to a time-independent neural network model (ANN), the number of parameters of the LSTM models should be comparable with the number of parameters used in the ANN. In this context, the number of weights of the tested models is within the same order of magnitude as the ANN model. A preliminary test has demonstrated that a more complex LSTM architecture does not improve the model's performance because it needs more training resources. The following three architectures allow us to evaluate the effect of hidden layers and stacked LSTM cells:

- **Model 1:** This model is formed by a LSTM cell layer followed by a dense layer. The LSTM cell captures the time-dependent features (input data) and creates an output layer of 64 values that summarize the complete information contained in that input data. Afterwards, a dense layer is applied. The objective of a dense layer is to relate the variables and to determine a prediction of the lateral car body accelerations taking into account the output of the LSTM cells (see Table 1).
- **Model 2:** this model is proving that stacking LSTM cells layers can lead to better results. This configuration allows the model to capture more complex time-dependent features. In some circumstances stacking LSTM layers can improve the performance

Table 2
Structure of model 2.

Layer (type)	Output shape
LSTM cells	(,t,32)
LSTM cells	(,32)
Dense	(,32)
Dense	(,1)

Table 3
Structure of model 3.

Layer (type)	Output shape
LSTM cells	(,32)
Dense	(,32)
Dense	(,1)

of the models with a strong sequential component, for example in Natural Language Processing or speech processing (see Table 2).

- **Model 3:** this model consists of one LSTM layer and two dense layers, in order to capture more complex relationships between variables, but not necessarily temporal relationships. As considering 6 layers structure in the dense network is achieving the best performance of the model, it is mandatory to test deeper architecture models (see Table 3).

For each model, the number of parameters depends on the time window dimension. Larger time windows lead to an increase of computing cost. The training process is implementing the Adam optimizer (Kingma and Ba, 2015) with a variable learning rate, which is reduced if no improvement is detected after 5 epochs. Models are trained for 100 epochs, however, the training process will finish after 10 consecutive epochs without considerable improvements in the validation set. Additionally, no overfitting is detected so dropout layers or regularization are not implemented.

Different time windows are tested: 2 s, 3 s, 4 s, 5 s, 8 s, 10 s, 15 s, the 20 s, 30 s, and 60 s. There is no clearance about the appropriate time slot to be considered in the data samples formation, as the dynamic behavior of the train is a characteristic changing even in less than 1 s. Therefore, it is difficult to determine scientifically this optimal batch duration so in this paper an empirical analysis is done for determining the optimal time slot to be considered for the data input.

To evaluate the performance of each model, three performance metrics are defined:

- **Mean Absolute Error:** a mean absolute error of 3% of the typical maximum estimated values for accelerations in vehicle body reflected in the EN 14363 for the passenger coaches ($1,5 \text{ m/s}^2$), which means approximately $0,05 \text{ m/s}^2$, will be considered a successful result after expert consultation (Martínez-Llop et al., 2021).
- **Maximum error:** a maximum error between the predicted values and the real values less than 20% of the typical maximum estimated values for accelerations in the vehicle body reflected in the EN 14363 for the passenger coaches ($1,5 \text{ m/s}^2$), which means $0,3 \text{ m/s}^2$, will be considered a successful result (Martínez-Llop et al., 2021).
- **Overflow error counter:** this metric reflects the percentage of data predicted with an error greater than $0,25 \text{ m/s}^2$. It is important to check that there is no excessive deviation of the error, so the reliability of the model is appropriate for its purpose. If less than 1% of the data exceeds $0,25 \text{ m/s}^2$ (15% of the typical maximum estimated values for accelerations in vehicle body reflected in the EN 14363 for the passenger coaches ($1,5 \text{ m/s}^2$)), it will be considered a successful result (Martínez-Llop et al., 2021).

Table 4

Results (Mean absolute error in m/s^2) of the 3 defined models considering the different time windows length.

Time window length										
	2	3	4	5	8	10	15	20	30	60
1	0,035	0,034	0,034	0,033	0,034	0,034	0,034	0,035	0,035	0,037
2	0,035	0,035	0,035	0,034	0,035	0,035	0,036	0,036	0,036	0,037
3	0,036	0,036	0,036	0,036	0,035	0,036	0,036	0,036	0,036	0,038

6. Failure detection by the algorithm and limit range for the error

Failure detection relies on the monitoring of the error prediction. As the suspension elements are being degraded, the train starts to behave dynamically differently. The neural network fails to predict accurately the degraded behavior, because the model is trained using only correct records of good dynamic behavior of the trains, without degraded components. Therefore, it can predict only the good behavior of the train. The train maintainers should store the mean absolute error and the standard deviation on the test dataset (step 1). In suspicious cases of comfort loss, the maintainer will run the predictions for the suspicious axles (step 2). The mean error committed by the neural network will be determined and will be also checked with a hypothesis contrast if there is enough evidence to affirm that the error committed by the neural network is bigger than a fixed threshold (step 3). We suggest the threshold to be calculated as the sum of M.A.E. (calculated in step 1) plus 3 times the standard deviation (calculated in step 1). Three times is considered after expert consultation in this specific train, but each maintainer in each train should select the specific deviation range. If the error (committed in step 2) is significantly higher than this threshold, this means that the axle is behaving differently, and therefore maintenance actions should be conducted. The manufacturer should adjust the threshold. The authors suggest training the neural networks with data gathered on the same tracks that the train is running, to avoid raising alarms because of the track condition instead of the rolling stock dynamic behavior.

7. Results

Several models are trained to predict the lateral acceleration of the car body (Ayc) as it is the most representative variable for the comfortability perceived by passengers on the train. A LSTM is trained for predicting the lateral car body acceleration of every axle. The first goal of the study is to find the best value for the time-sliding window to be considered for the model. For this purpose, the mean absolute error in the test set is evaluated. The results for the 3 defined architectures are shown in Table 4.

The results indicate that the best value for the time-sliding window to consider as an input for the model is 5 s for models 1 and 2 and 8 s for model 3. The performance of the third model considering 5 s window is almost the same. Considering also that the computing cost for an 8 s window is larger than for a 5 s window the ideal time window to consider for this problem resolution is 5 s.

This time window determined may be different in other trains as it has a strong dependence on the dynamic behavior of every particular train. Another important conclusion is that long-time dependencies are not improving the predictions, apart from the higher computational cost required.

To evaluate the best model architecture the three metrics are taken into account: the mean absolute error is a good key performance indicator, but also it is important to consider that no frequent big values are predicted so false alarms are enabled, and the comfort degradation detection is losing robustness. The results of the three key performance indicators of each model are shown in Table 5.

The conclusion drawn from this experiment is that the best performance is achieved with the least complex model, which is Model 1 as the mean absolute error is smaller, it has less overflow and the maximum error seems acceptable considering the criteria described in the previous chapter.

Table 5

Key performance indicators of the defined models.

Model	Mean absolute error (m/s^2)	Maximum error (m/s^2)	Overflow error counter (%)
Model 1	0,0335	0,349	0,064
Model 2	0,0340	0,381	0,074
Model 3	0,0355	0,309	0,074

Table 6

Comparison between the performance of a DNN Martínez-Llop et al. (2021) and the best-obtained model, model 1.

Ayc-mean absolute error	Dense neural network (m/s^2)	LSTM – model 1 (m/s^2)	Gain (%)
Axle 1	0,0542	0,0400	26,2%
Axle 3	0,0361	0,0331	8,3%
Axle 5	0,0342	0,0318	7,0%
Axle 7	0,0345	0,0329	4,6%
Axle 9	0,0339	0,0297	12,4%

7.1. Comparison with time-independent model.

Another important result in this paper is to determine how much the real-time variable consideration is impacting the model's performance. Once the correct time window has been selected, a comparison between the time-dependence model (developed in this study) and time-independence model developed in Martínez-Llop et al. (2021) is done, which is composed of 6 dense layers with 64 neurons in the hidden layers. Although generating the time-window data packages are time-consuming, it is highly compensated by the increase in performance.

As it is shown in Fig. 3, comparing axles 1 and 5, it is demonstrated that all models developed in this paper are achieving better performances than the time-independence model developed in Martínez-Llop et al. (2021) (see Fig. 5).

It seems reasonable that a predicting model of dynamic behavior, which is directly related to the time variable, is performing better than a time-independent model. Inertia, roll, pitch, or yaw are time-dependent variables are affecting the predictions.

In Table 6, a comparison between the optimized model (model 1) and the time-independence model defined in Martínez-Llop et al. (2021) is presented. Better performance is obtained, and a very interesting result is that the performance gain in extreme axles such as axle 1 is much higher than in the other axles. Those axles are not guided and their dynamic behavior is more complex compared to the intermediate axles. Therefore, a time-dependent model has more information as it also takes into account past states as an input. This happens because the ANN can only take information about the extreme axles from the values registered in non-extreme axles. Since the dynamic behavior of extreme axles is different, the model has more difficulties to predict the acceleration value using only the other axles' measurements. In the LSTM network, the model can use the behavior of the extreme axle over the last seconds added to the previous information and is capable of achieving better results.

8. Model's performance on a real case of application

As it was done in the referenced study (Martínez-Llop et al., 2021), a real comfort-degradation case detection is introduced to model 1 to check if a clear detection of this not normal behavior is detected. Any alarm was triggered from the train as the safety limits were never reached but passengers noted in this specific trip a loss of comfort due to the lateral movement of the coach. A subsequent check during maintenance inspection revealed that a component adjustment was needed, so a potential failure or component maladjustment is detected. This methodology could be implemented in other train types, but the specific algorithm is optimized in each train type. As the different trains




Fig. 5. Performance comparison between the time-independence model (Martínez-Llop et al., 2021) and the developed models in this paper.

share the same principal components and design, the methodology can be extrapolated to the entire fleet.

The networks used for this purpose are previously trained with the precedent dataset. The real comfort degradation case dataset is composed of 10000 samples. They are transformed using the same standard scaler as in the network training phase. This algorithm is trained to detect significant differences between predicted behavior and real behavior. As the pre-trained network characterizes the correct behavior of the car body accelerations, a significant difference underlies a loss of comfort and should trigger an inspection of the suspension and damping elements.

The results of the real comfort degradation case are shown in Table 7. Abnormal behavior is detected in axles 10–13, which register a larger mean absolute error between the predictions and reality. More specifically, using the mean absolute error and the overflow error counter, the problem seems to be in axle 11. Indeed, the passenger was sitting on coach 11 which leans on axles 11 and 12.

This verification case reflects the potential good performance of this model in a global CBM program definition. The neural network model can trigger an alarm when comfort loss is detected and much before the safety limits are reached.

In Table 7, it is also presented the p -value calculated in this real case, and it is demonstrated that the comfort loss is reached in axles

Table 7

Optimized model 1 results of the real comfort degradation case.

Ayc	Evaluation of real case of application in 2019				
	Mean absolute error (m/s ²)	Maximum error (m/s ²)	Overflow error Counter (%)	Threshold	p-value
Axle 1	0,0725	1,31	2,20	0.193	0.97
Axle 3	0,0454	0,47	0,27	0.150	0.99
Axle 5	0,0357	0,35	0,01	0.146	0.99
Axle 7	0,0436	0,37	0,01	0.147	0.99
Axle 9	0,0426	0,52	0,09	0.144	0.99
Axle 10	0,2076	2,25	0,07	0.165	0.14
Axle 11	0,6320	1,59	74,26	0.149	0.02
Axle 12	0,3534	1,37	0,04	0.152	0.12
Axle 13	0,0996	0,76	3,36	0.201	0.79

10–12 not only due to the error committed by the algorithm, but also because the reduced value of p — value that reaffirm the extreme values of this predictions compared to the normal ones (healthy train which means a good dynamic behavior).

In Fig. 6 the difference between the predicted lateral acceleration values (Ayc) and the real lateral acceleration values are represented.

The difference between the model and the measures is larger for the axle where the comfort loss is detected. This helped to identify the exact




Fig. 6. Difference between the predicted lateral acceleration values (A_{yc}) and the real lateral acceleration values.

axle where the comfort loss occurred. Comparing these results with the ones obtained in the time-independent model (Martínez-Llop et al., 2021), both experiments present very similar results. Both methods determined where the problem was located with equivalent performances. In this case, the degradation of a suspension component causes a loss of comfort and is detected by a passenger. This example shows the workflow that this LSTM-based model enables. By monitoring the error between the real measurements and the machine learning predictions, it is possible to detect unusual behavior and take maintenance actions before reaching safety levels or having more passenger complaints. This example shows how the loss of comfort of the passenger is captured by monitoring the model error.

9. Conclusions

This paper highlights the benefits of using time-dependent models when assessing comfort losses due to car body lateral accelerations with machine learning implementation. The recurrent neural network structure performed better for the same order of magnitude number of parameters compared to the Artificial Neural Network. The ideal length for the time window to be used is 5 s, beyond this length performance decreases when training with a broader window. This model can detect the loss of comfort in a real-case scenario where any safety level was reached. The model identified where the comfort loss was located and is, therefore, an advantage as part of a condition-based maintenance strategy. It is encouraged to keep the architecture of the neural network simple. Adding layers or stacking LSTM layers is not improving the results while increasing complexity and training-associated computational costs. Another important practical fact is that

no additional sensors are needed for this application as the information used is proceeding for the current accelerometers installed in the trains.

This study demonstrates that using LSTM-based architecture improved significantly the performance of predicting lateral car body acceleration values which is the target value for the comfort perception by passengers. A minimum average of $0,033 \text{ m/s}^2$ is obtained as MAE in model 1 grouping the input data in 5 s packages as stated before. This error is less than 2,5% of the typical maximum estimated values for accelerations in the vehicle body as reflected in the standard EN14363 (DIN EN 14363 2016-10, 2016).

Time-dependent features are relevant in this regression problem and are worth to be taken into account. The accuracy obtained with these models could justify the additional computational cost incurred in pre-processing. As the LSTM model 1 architecture is relatively flat, the computational cost is within the same order of magnitude as an ANN model solving the same problem. The three LSTM-based models tested worked better than the time-independent neural network and this proves that the addition of an LSTM layer improves the model's performance.

This paper proved that stacking LSTM layers does not impact model performance, as it can happen in Natural Language Processing (NLP) or speech recognition applications. A flatter and larger model architecture is recommended.

Results obtained with the optimal LSTM model are better than the ANN model, so the comfort degradation detection is solved with this LSTM model with higher precision.

In addition, LSTM models are appropriate for estimating remaining useful life (Aydin and Guldamsioglu, 2017; Shi and Chehade, 2021; Mao et al., 2018). This idea is worth to be studied in the future: as

ANN models or LSTM models seem to solve the comfort degradation detection with good results, the number of arguments to use LSTM-based models grows if it allows earlier loss of comfort detection. For this reason, an important future topic to be solved is the remaining time before the comfort loss is starting to be detected by passengers. Therefore, a future investigation could use the real data deviation from the LSTM model as an indicator to be taken into account when estimating the remaining useful life.

Declaration of competing interest

The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

Data availability

The data that has been used is confidential.

References

- Ai, B., et al., 2015. Future railway services-oriented mobile communications network. *IEEE Commun. Mag.* 53 (10), 78–85. <http://dx.doi.org/10.1109/MCOM.2015.7295467>.
- Anon, 2017. Figure obtained from. <https://pydeeplearning.weebly.com/blog/basic-architecture-of-rnn-and-lstm>.
- Aydin, Olgun, Guldamlasioglu, Seren, 2017. Using LSTM networks to predict engine condition on large scale data processing framework, 2017. In: 4th International Conference on Electrical and Electronic Engineering. ICEEE, IEEE, pp. 281–285.
- Beard, G.F., Griffin, M.J., 2013. Discomfort during lateral acceleration: Influence of seat cushion and backrest. *Appl. Ergon.* 44 (4), 588–594. <http://dx.doi.org/10.1016/j.apergo.2012.11.009>, Epub 2013 Jan 9. PMID: 23312371.
- Celiński, I., Burdzik, R., Młyński, J., Kłaczynski, M., 2022. Research on the applicability of vibration signals for real-time train and track condition monitoring. *Sensors* 22, 2368. <http://dx.doi.org/10.3390/s22062368>.
- Daily, J., Jeff, P., 2017. Predictive maintenance: How big data analysis can improve maintenance. In: Supply Chain Integration Challenges in Commercial Aerospace. Springer, Cham.
- Davari, N., Veloso, B., Ribeiro, R.P., Pereira, P.M., Gama, J., 2021. Predictive maintenance based on anomaly detection using deep learning for air production unit in the railway industry. In: Proceedings of the 2021 IEEE 8th International Conference on Data Science and Advanced Analytics. DSAA, Porto, Portugal, pp. 6–9.
- de Pater, Ingeborg, Mitici, Mihaela, 2023. Developing health indicators and RUL prognostics for systems with few failure instances and varying operating conditions using a LSTM autoencoder. *Eng. Appl. Artif. Intell.* (ISSN: 0952-1976) 117 (Part A), 105582. <http://dx.doi.org/10.1016/j.engappai.2022.105582>.
- DIN EN 12299:2009-08, 2009. Railway applications - Ride comfort for passengers - Measurement and evaluation.
- DIN EN 14363 2016-10, 2016. Railway applications - Testing and Simulation for the acceptance of running characteristics of railway vehicles - Running Behaviour and stationary tests.
- Dižo, Ján, et al., 2021. Evaluation of ride comfort in a railway passenger car depending on a change of suspension parameters. *Sensors* 21 (23), 8138.
- Du, Simon, et al., 2019. Gradient descent finds global minima of deep neural networks. In: En International Conference on Machine Learning. PMLR, pp. 1675–1685.
- Dyer, Chris, et al., 2016. Recurrent neural network grammars. *arXiv preprint arXiv:1602.07776*.
- El Said, Abd El Rahman, Wild, Brandon, Higgins, James, Desell, Travis, 2016. Using LSTM recurrent neural networks to predict excess vibration events in aircraft engines. pp. 260–269. <http://dx.doi.org/10.1109/eScience.2016.7870907>.
- Ersöz, O.Ö., Inal, A.F., Aktepe, A., Türker, A.K., Ersöz, S., 2022. A systematic literature review of the predictive maintenance from transportation systems aspect. *Sustainability* 14, 14536. <http://dx.doi.org/10.3390/su142114536>.
- Farahani, B.V., Barros, F., Sousa, P.J., Tavares, P.J., Moreira, P.M.G.P., 2020. A railway tunnel structural monitoring methodology proposal for predictive maintenance. In: Structural Control and Health Monitoring, Vol. 27, no. 8.
- Graa, M., Nejlaoui, M., Houidi, A., Affi, Z., Romdhane, L., 2015. Modeling and simulation for vertical rail vehicle dynamic vibration with comfort evaluation. In: Haddar, M., et al. (Eds.), Multiphysics Modelling and Simulation for Systems Design and Monitoring. MMSSD 2014, In: Applied Condition Monitoring, vol 2, Springer, Cham, http://dx.doi.org/10.1007/978-3-319-14532-7_6.
- Guo, Jingwei, Wang, Wei, Tang, Yinying, Zhang, Yongxiang, Zhuge, Hengying, 2022. A CNN-BiLSTM parallel network approach for train travel time prediction. *Knowl.-Based Syst.* (ISSN: 0950-7051) 256, 109796. <http://dx.doi.org/10.1016/j.knsys.2022.109796>.
- Han, S.-H., 2013. A study on the ride comfort control using automatic generating database on board for electric railway vehicle (ICCAS 2013). In: 2013 13th International Conference on Control, Automation and Systems. ICCAS 2013, pp. 464–465. <http://dx.doi.org/10.1109/ICCAS.2013.6703975>.
- Heinold, A., Meisel, F., 2018. Emission rates of intermodal rail/road and road-only transportation in Europe: A comprehensive simulation study. *Transp. Res. Part D: Transp. Environ.* 65, 421–437.
- Hoffrichter, Andreas, Hillmans, Stuart, Roberts, Clive, 2016. Conceptual propulsion system design for a hydrogen-powered regional train. *IET Electr. Syst. Transp.* 6 (2), 56–66.
- Hoogma, Remco, et al., 2002. Experimenting for Sustainable Transport. Taylor & Francis Group, ISBN: 9780415271172.
- Hu, L., Dai, G., 2022. Estimate remaining useful life for predictive railways maintenance based on LSTM autoencoder. *Neural Comput. Appl.* <http://dx.doi.org/10.1007/s00521-021-06051-1>.
- Huang, Junhui, Kaewunruen, Sakdirat, 2022. Evaluation of railway passenger comfort with machine learning. *IEEE ACCESS* 10, 2372–2381.
- IPCC, 2007. Core writing team. In: Climate Change 2007: Synthesis Report. In: Contribution of working groups I, II and III to the fourth assessment report of the intergovernmental panel on climate change, chapter 5, section 5.3.2.
- Jiateng, Y., Wentian, Z., 2016. Fault diagnosis network design for vehicle on-board equipments of high-speed railway: A deep learning approach. *Eng. Appl. Artif. Intell.* (ISSN: 0952-1976) 56, 250–259.
- Jones-Lee, Michael W., Jones-Lee, Michael, 1990. The value of transport safety. *Oxf. Rev. Econ. Policy* 6 (2), 39–60.
- Karakasis, Kleomenis, Skarlatos, Dimitris, Zakinthinos, Tilemachos, 2005. A factorial analysis for the determination of an optimal train speed with a desired ride comfort. *Appl. Acoust.* - APPL ACOUST. 66, 1121–1134. <http://dx.doi.org/10.1016/j.apacoust.2005.02.006>.
- Kingma, D.P., Ba, J., 2015. Adam: A method for stochastic optimization. In: International Conference on Learning Representations. ICLR.
- La Paglia, Ivano, Carnevale, Marco, Corradi, Roberto, Di Galleonardo, Egidio, Facchinetti, Alan, Lisi, Stefano, 2023. Condition monitoring of vertical track alignment by bogie acceleration measurements on commercial high-speed vehicles. *Mech. Syst. Signal Process.* (ISSN: 0888-3270) 186, 109869. <http://dx.doi.org/10.1016/j.ymssp.2022.109869>.
- Ma, Q., Peng, Y., Luo, P., Li, Q., Wang, H., Yu, J., 2020. A traction load forecasting method of electrified railway based on LSTM. In: 2020 IEEE 9th International Power Electronics and Motion Control Conference. IPEMC2020-ECCE Asia, pp. 2861–2866. <http://dx.doi.org/10.1109/IPEMC-ECCEAsia48364.2020.9368205>.
- Mai, O., Shohei, A., Yasukumi, N., Hirotaka, M., Hitoshi, T., 2017. Track geometry estimation of a conventional railway from car-body acceleration measurement. *Mech. Eng. J.* 4 (1), 16–00498.
- Mao, Wentao, et al., 2018. Predicting remaining useful life of rolling bearings based on deep feature representation and long short-term memory neural network. *Adv. Mech. Eng.* 10 (12), 1687814018817184.
- Martínez-Llop, P.G., Sanz Bobi, J.d.D., Solano Jiménez, Á., Gutiérrez Sánchez, J., 2021. Condition-based maintenance for normal behaviour characterisation of railway car-body acceleration applying neural networks. *Sustainability* 13, 12265. <http://dx.doi.org/10.3390/su132112265>.
- Men, Tianli, Li, Yan-Fu, Ji, Yujun, Zhang, Xinliang, Liu, Pengfei, 2022. Health assessment of high-speed train wheels based on group-profile data. *Reliab. Eng. Syst. Saf.* (ISSN: 0951-8320) 223, 108496. <http://dx.doi.org/10.1016/j.res.2022.108496>.
- Ngigi, R.W., et al., 2012. Modern techniques for condition monitoring of railway vehicle dynamics. In: Journal of Physics: Conference Series, Vol. 364. COMADEM 2012 18–20 2012, Huddersfield, UK. Conf. Ser. 364 012016, In: 25th International Congress on Condition Monitoring and Diagnostic Engineering.
- Roberto, Rocchetta, Gao, Qi, Mavroeidis, Dimitrios, Petkovic, Milan, 2022. A robust model selection framework for fault detection and system health monitoring with limited failure examples: Heterogeneous data fusion and formal sensitivity bounds. *Eng. Appl. Artif. Intell.* (ISSN: 0952-1976) 114, 105140.
- Rojas, R., 1996. The backpropagation algorithm. In: Neural Networks. Springer, Berlin, Heidelberg.
- Shi, Z., Chehade, A., 2021. A dual-LSTM framework combining change point detection and remaining useful life prediction. *Reliab. Eng. Syst. Saf.* 205, 107257.
- Sibi, P., Jones, S., Allwyn, Siddarth, P., 2013. Analysis of different activation functions using back propagation neural networks. *J. Theoret. Appl. Inform. Technol.* 47 (3), 1264–1268.
- Siefert, A., Pankoke, S., Wölfel, H.-P., 2008. Virtual optimisation of car passenger seats: Simulation of static and dynamic effects on drivers' seating comfort. *Int. J. Ind. Ergon.* (ISSN: 0169-8141) 38 (5–6), 410–424. <http://dx.doi.org/10.1016/j.ergon.2007.08.016>.
- Ting, H., Chi Wai, T., King, H., Edward, C., 2023. Anomaly detection of train wheels utilizing short-time Fourier transform and unsupervised learning algorithms. *Eng. Appl. Artif. Intell.* (ISSN: 0952-1976) 122, 106037. <http://dx.doi.org/10.1016/j.engappai.2023.106037>.
- Varsanopoulos, Savvas, Bertels, Koen, Almudever, Carmen, 2018. Designing neural network based decoders for surface codes.

- Wu, Jun, Qiu, Yi, 2020. Analysis of ride comfort of high-speed train based on a train-seat-human model in the vertical direction. *Veh. Syst. Dyn.* 59, <http://dx.doi.org/10.1080/00423114.2020.1794014>.
- Xiukun, W., Feng, L., Limin, J., 2016. Urban rail track condition monitoring based on in-service vehicle acceleration measurements. *Measurement* 80, 217–228.
- Ye, Y., Huang, P., Zhang, Y., 2022. Deep learning-based fault diagnostic network of high-speed train secondary suspension systems for immunity to track irregularities and wheel wear. *Rail. Eng. Sci.* 30, 96–116. <http://dx.doi.org/10.1007/s40534-021-00252-z>.
- Zaremba, Wojciech, Sutskever, Ilya, Vinyals, Oriol, 2014. Recurrent neural network regularization. *arXiv preprint* [arXiv:1409.2329](https://arxiv.org/abs/1409.2329).
- Zeng, L., Zhang, H., Han, Q. others, 2023. An LSTM-based driving operation suggestion method for riding comfort-oriented critical zone. *J. Ambient Intell. Human. Comput.* 14, 755–771. <http://dx.doi.org/10.1007/s12652-021-03327-1>.
- Zhai, Wanming, Liu, Pengfei, Lin, Jianhui, Wang, Kaiyun, 2015. Experimental investigation on vibration behavior of a CRH train at speed of 350 km/h. *Int. J. Rail Transp.* 3 (1), 1–16. <http://dx.doi.org/10.1080/23248378.2014.992819>.
- Zhang, Y., Zhu, J., Zhang, J., Junfeng, J., Jia, L., Limin, Q., Yong, S., Jianguo, F., Feng, J., Jianghua, D., Diao, Lijun y An, Min, 2018. *Short-Term Passenger Flow Forecasting Based on Phase Space Reconstruction and LSTM*. Springer Singapore, SINGAPORE, ISBN: 978-981-10-7985-6.



sustainability

IMPACT
FACTOR
3.9

CITESCORE
5.8

Article

Condition-Based Maintenance for Normal Behaviour Characterisation of Railway Car-Body Acceleration Applying Neural Networks

Pablo Garrido Martínez-Llop, Juan de Dios Sanz Bobi, Álvaro Solano Jiménez and Jorge Gutiérrez Sánchez

Special Issue

Sustainable and Trustworthy Operation and Maintenance of Railway Systems

Edited by

Prof. Dr. Ramin Karim, Prof. Dr. Uday Kumar and Prof. Dr. Diego Galar



<https://doi.org/10.3390/su132112265>

Article

Condition-Based Maintenance for Normal Behaviour Characterisation of Railway Car-Body Acceleration Applying Neural Networks

Pablo Garrido Martínez-Llop , Juan de Dios Sanz Bobi , Álvaro Solano Jiménez and Jorge Gutiérrez Sánchez

Department of Applied Mathematics in Industrial Engineering and Mechanical Engineering Department, Universidad Politécnica de Madrid, 28040 Madrid, Spain; juandedios.sanz@upm.es (J.d.D.S.B.); alvarosolano333@gmail.com (Á.S.J.); jorge.gutierrez.sanchez@alumnos.upm.es (J.G.S.)

* Correspondence: pablo.garrido@upm.es



Citation: Martínez-Llop, P.G.; Sanz Bobi, J.d.D.; Solano Jiménez, Á.; Gutiérrez Sánchez, J. Condition-Based Maintenance for Normal Behaviour Characterisation of Railway Car-Body Acceleration Applying Neural Networks. *Sustainability* **2021**, *13*, 12265. <https://doi.org/10.3390/su132112265>

Academic Editors: Ramin Karim, Uday Kumar and Diego Galar

Received: 21 September 2021

Accepted: 1 November 2021

Published: 6 November 2021

Publisher's Note: MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



Copyright: © 2021 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

Abstract: Recently, passenger comfort and user experience are becoming increasingly relevant for the railway operators and, therefore, for railway manufacturers as well. The main reason for this to happen is that comfort is a clear differential value considered by passengers as final customers. Passengers' comfort is directly related to the accelerations received through the car-body of the train. For this reason, suspension and damping components must be maintained in perfect condition, assuring high levels of comfort quality. An early detection of any potential failure in these systems derives in a better maintenance inspections' planification and in a more sustainable approach to the whole train maintenance strategy. In this paper, an optimized model based on neural networks is trained in order to predict lateral car-body accelerations. Comparing these predictions to the values measured on the train, a normal characterisation of the lateral dynamic behaviour can be determined. Any deviation from this normal characterisation will imply a comfort loss or a potential degradation of the suspension and damping components. This model has been trained with a dataset from a specific train unit, containing variables recorded every second during the year 2017, including lateral and vertical car-body accelerations, among others. A minimum average error of 0.034 m/s^2 is obtained in the prediction of lateral car-body accelerations. This means that the average error is approximately 2.27% of the typical maximum estimated values for accelerations in vehicle body reflected in the EN14363 for the passenger coaches (1.5 m/s^2). Thus, a successful model is achieved. In addition, the model is evaluated based on a real situation in which a passenger noticed a lack of comfort, achieving excellent results in the detection of atypical accelerations. Therefore, as it is possible to measure acceleration deviations from the standard behaviour causing lack of comfort in passengers, an alert can be sent to the operator or the maintainer for a non-programmed intervention at depot (predictive maintenance) or on board (prescriptive maintenance). As a result, a condition-based maintenance (CBM) methodology is proposed to avoid comfort degradation that could end in passenger complaints or speed limitation due to safety reasons for excessive acceleration. This methodology highlights a sustainable maintenance concept and an energy efficiency strategy.

Keywords: condition-based maintenance; machine learning; deep learning; predictive maintenance; comfort; railway dynamics; user experience; artificial neural networks; railway safety; railway reliability; car-body accelerations; comfort degradation

1. Introduction

In the railway industry, safety has always been prioritized against other variables [1,2]. Nowadays, maximum levels of safety are guaranteed by the state-of-art. For example, signalling systems continue increasing their safety levels, avoiding human errors, and reducing potential risks [3]. From the operator's point of view, it is also important to optimize and reach high values of reliability, availability, and maintainability of the principal train components. In that sense, less interventions will be needed, less incidences will

occur during commercial services, and no deviation for the rail service planned scheduling should emerge. These concepts are directly related with the technical part of the train, but not with the interphase between the final users and the operator. For this reason, another very important concept arises: user experience and passenger comfort.

Since the beginning, the main goal of the different means of transport was transporting people or goods from one place to another. Passenger expectations were limited to acquiring this basic service. Due to technological progress, a more complete service has been offered to the final users, with a consequent increase in the expectations and requirements from the passengers. In the last few years, user experience has emerged as a new concept because passengers are demanding not only a mere trip, but also a memorable experience.

In relation to passengers' satisfactory experience in the train, it is also essential to offer a very high degree of comfortability, avoiding train wobbles or sudden movements. Many sensors and electronics are being used to supervise railway dynamics and infrastructures [4], focusing on safety assurance and contributing to the condition-based maintenance topic. Generally, the three main reasons that cause a feeling of comfort loss in passengers are: punctual track irregularities that generate acceleration peaks [5], a non-optimized guidance of the train that can cause a constant loss of comfort over time [6], and the malfunctioning of any of the components implicated in the dynamic behaviour of the train (damping and suspension) that can also cause an extended loss of comfort. The implemented methodology in this study is focused on the second and third cases because it intends to detect lack of comfort that can lead to an uncomfortable experience for passengers. These cases can also derive in potential failures of suspension and damping components, so their early detection is essential to create a predictive maintenance strategy.

In this paper, an artificial neural network model is developed with the aim of detecting comfort degradation in the train, with the lateral car-body acceleration as a target variable to be predicted. The prediction is based on the interrelation between all the accelerations measured in each instant of time: lateral and vertical car-body accelerations, lateral wheelset accelerations, and the train's overall speed. Based on these variables, the algorithm is trained to characterise the good behaviour of the car-body accelerations (high quality comfort) using real data obtained from healthy trains (with no damping or suspension damaged or worn components). A comfort loss or damaged component is detected once the difference between the real value of lateral car-body acceleration and the predicted value for this acceleration becomes noticeable.

In the state-of-the-art, there are many studies that achieve excellent results in predicting the accelerations of the train's coaches. In fact, some of them use advanced predictive algorithms such as neural networks and statistical correlations to predict this variable [7,8]. In addition, other studies address the prediction of comfort values in high-speed trains using multibody dynamic models, including information about the track geometry and a simplified model of the rolling stock [9,10]. However, there is not any study that merges these two ideas together in a mathematical and engineering sense. The intention of this study is to address the prediction of the lateral car-body acceleration in a high-speed train using a neural network for the following purpose: the implementation of a methodology that compares these predictions to the real values measured on the train in order to obtain a continuous monitorization of comfort status in the train. Testing this methodology with a real case of application achieves a continuous onboard monitorization system of comfort degradation. The norm EN12299 [11] is validating ride comfort for passengers only once during the certification process of the train in case it is contractually required, but it is not offering a methodology for a continuous monitorization of the train ride comfort for passengers.

In this sense, the railway sector needs to continue evolving considering this new condition-based maintenance (CBM) concept, not only for maintenance cost optimization but also to improve passengers' comfort and, therefore, user experience. The methodology and the results are useful to develop an on-board health monitoring system [12,13], with two main goals: contribute to a predictive and more sustainable maintenance strategy

aligned with the CBM concept, and to improve the user experience concept, fulfilling passenger's comfort expectations. The first objective will satisfy operators, manufacturers, and maintainers, as the maintenance concept has evolved from the traditional corrective maintenance to the predictive and prescriptive maintenance, which is still being developed as part of the CBM [14]. The second objective will satisfy the entire railway sector, including the final users [15].

The optimized model is an excellent contribution to the early detection of comfort degradation or any failure in the damping system that could cause speed limitation, or even the declaration of a useless train due to safety concerns. In this case, operators or manufacturers might incur high penalties for the delay produced. In addition to this, an optimization of resources is reached through the identification of anomalies and deficiency patterns in order to trigger alerts when a component is coming to the end of its life [16].

Furthermore, the algorithm and methodology developed in this paper offers a key performance indicator (KPI) of the train comfort degradation measured in real time. This KPI fulfils two main objectives: identify the comfort loss in a very advanced phase before it is noticeable by the passengers, and predict an imminent failure mode of the train damping or suspension's components. This prediction is based on the comparison between the predicted lateral acceleration values and the real time monitored values. If a deviation between both curves is detected and the difference is constantly increasing, then an early comfort loss is identified, or even a potential component failure is detected.

As a consequence, a good implementation of predictive maintenance is surely causing clear economic benefits and contributing to the sustainability of the whole maintenance process [17,18]. Newly, sustainable transportation is becoming a key issue to reduce emissions and to address energetic efficiency that leads to a lower environmental impact.

2. Theoretical and Mathematical Foundations

An Artificial Neural Network (ANN) is an iterative computer model commonly used in Machine Learning applications that learns certain behaviours, patterns, or relationships (especially non-linear relationships) from given data, and uses that knowledge to make predictions. Generally, ANNs are based on a set of simple, constructively identical nodes, called artificial neurons or perceptrons. These perceptrons are grouped in layers, so that all the perceptrons in one layer are connected to all the perceptrons in the next layer, allowing the transmission of information between layers of the ANN. Each neuron receives the values of the outputs (activations), computed by the neurons of the previous layer as an input. Equivalently, neurons compute the activation that will be sent to downstream neurons. Each neuron is characterised by the following trainable parameters: w_i (weight) and b (independent term), as shown in the structure of an artificial neuron in Figure 1.




Figure 1. Structure of an artificial neuron.

In Figure 1, x_i represents the i^{th} training sample that comes as an input to the neuron, and a represents the output. The output of the last neuron of the neural net corresponds to the final predicted value for the i^{th} training sample.

The inputs or activations received are subjected firstly to a linear operation, and secondly to a non-linear operation. The linear operation can be expressed by:

$$z = \sum_i (w_i \times a_{i-1}) + b \quad (1)$$

where z represents the result of the linear operation, w_i represents the weight vector for the i^{th} training sample, a_{i-1} represents the output of the previous neuron taken as the input in this neuron, and b represents the bias value for that neuron.

The non-linear operation or activation phase is implemented, in this case using ReLU functions, and can be expressed by:

$$a = g(z) \quad (2)$$

where the function $g(z)$ represents the ReLU function and z represents the output of that neuron.

As mentioned before, neurons are displayed within three types of layers: the input layer, hidden layers, and the output layer. The number of hidden layers in a neural network depends on the problem to be solved and is a hyper parameter of the model that must be optimized to maximize its accuracy. Setting a high number of layers makes a deeper and more complex neural network. The idea behind building an ANN model is that it can learn and extract intrinsic relationships from the provided data, being able to generalise the normal behaviour of the train and use that knowledge to predict accelerations and spot anomalies. In order to achieve this, the ANN learning process which is applied to the data (actually not the full dataset, only the training set) can be divided into different phases.

First, the model's trainable parameters are randomly initialized with a standard normal random distribution of zero mean and unit variance. For better performance in this paper, He normal initializer is also applied [19,20], which is commonly used for ReLU activation functions. Once the model's parameters are initialized, the data is introduced into the input layer of the artificial neural network and a random prediction (due to random initialization of parameters) is made after computing the operations in the neurons. The aim of the model is to get a better prediction after every iteration, as learning algorithms are generally based on iterative numerical methods that minimize the error of the predicted values. The error value is quantified through a cost function, which is the objective function of the computational model. The cost is computed by comparing the predictions to the real values (target values).

In order to update the trainable parameters of the model and keep reducing the error value, gradients of the cost function with respect of the variables are computed. Since the calculated gradient points are in the direction of maximum cost growth, the model parameters are updated, moving in the opposite direction of the gradient. This phase is called "gradient descent", and parameters are updated based on the "backward propagation" algorithm [21]. At the end, a numerical optimization method is used to estimate the best parameters to minimize the cost function. At this point, the model has succeeded in finding the parameters that result in the lowest error value, and, therefore, it could be said that the model is already trained and static (fine tune of the model is done later).

As mentioned before, the aim of this study is to predict the lateral car-body acceleration, which is the most representative variable to characterise the comfort status perceived by the passengers in the train. The reason for this is that lateral acceleration is the less controlled acceleration of the train: longitudinally, the train is guided by the previous coach, and vertically, the train is supported by the wheelset and secondary suspension. Therefore, lateral accelerations are directly perceived by the passengers as the vertical acceleration is partially mitigated by the floor and other components between the structure and the seats. For this purpose, the column (feature) of the lateral car-body acceleration will be predicted separately, and afterwards compared with the real values to check the performance of the model. Therefore, this corresponds to a regression task in which lateral car-body acceleration is predicted (target variable) attending to the other variables in the dataset (predictors).

The ANN training is performed by iterating over epochs until the model parameters converge to successful values. The function to be finally optimized is the cost function, which is defined in the next section as the sum of all the differences between the predicted value and the real value.

3. Data Preparation and Statistical Analysis

In this paper, existing data from a specific high-speed train model has been used. A dataset of one year is considered representative for this study, as enough samples are registered for a model optimization and all particular situations due to the fact that external conditions are contemplated in this period of time. The dataset corresponds to the year 2017. The selected type of train operates in lines at a maximum speed of 300 km/h. Madrid-Valencia is an example of these lines. This particular trainset is formed by two power heads and 12 passenger coaches, but includes 13 axes because the 6th coach has a double axis as it is represented in Figure 2. The maximum weight per axle is 22.5 t and the distance between them is 13.3 m.




Figure 2. High-speed train layout used for this study.

Many variables are registered in a high-speed train. Some of them are continuous signals, such as temperatures or accelerations, and others are state variables, such as the status of the pantograph (up or down). The dataset used in this study contains the following continuous variables recorded in real time: train speed (v), exterior temperature (Text), bearing temperatures (T0–T3 as there are 4 bearing temperature sensors per axle), braking pressure (p), lateral wheelset acceleration (A_{yr}), lateral car-body acceleration (A_{yc}), and vertical car-body acceleration (A_{zc}) of all of the 12 coaches of the trainset.

In Figures 3 and 4, the signal of bearings' temperatures and accelerations are plotted for axle 5 as an illustration of these features' behaviour.




Figure 3. Bearings' temperatures in degrees centigrade over time.




Figure 4. Lateral and vertical accelerations (m/s^2) over time.

Each row of the dataset contains the values of the mentioned variables measured by the sensors in one instant of time (one second).

In the case of the accelerations, it is important to highlight that the recorded values are statistical values calculated as the root mean square values over 5-s intervals of frequency-weighted accelerations according to the norm EN12299 [17]. The train is equipped with 12 car-body accelerometers (one in each coach) that record lateral (Ayc) and vertical (Azc) car-body accelerations. In the case of the wheelset, there are 2 accelerometers per axle, so a total amount of 34 accelerometers are installed in the train (13 axles in the coaches and 8 accelerometers in the power head bogies) that measure the lateral wheelset acceleration values (Ayr). Figure 5 represents the position of the acceleration sensors of the car-body. These sensors are placed in the upper part of the endwall of the coaches due to the easy accessibility of this component for maintenance replacement or inspection. These sensors are accessible through the exterior door mechanism in the left part, as indicated in Figure 5. The dimensions are approximately $100 \times 35 \text{ mm}$, and the rolling lateral acceleration sensor is placed in the central part of the frame of the wheelset. The wheelsets are always located between two coaches.




Figure 5. Car-body acceleration sensor location.

The sensors are composed by one accelerometer, one band-pass filter ($>24 \text{ dB/octave}$), a U/I converter, and a power supply. The configuration of the sensor is presented in Figure 6.

This configuration applies for the car-body and wheelset sensors. The only difference between both is that the car-body sensors are biaxial accelerometers (to measure lateral and vertical accelerations), and the wheelset sensor is uniaxial as only the lateral acceleration is measured. The frequency range of the band-pass filter is between 0.4 and 10 Hz. 4–10 Hz. Outside this band, there is an attenuation of 3 dB (70% of the signal), with a gradient of greater than 24 dB/octave, with a tolerance of $\pm 0.5 \text{ dB}$ within the band, and $\pm 1 \text{ dB}$ outside

the band. It must be highlighted that synchronization of the sensors is assured as all the electronics that are recording the sensor's measurements are connected to the TCMS (train control and management system).




Figure 6. Configuration of the sensors.

In general terms, data registered by the sensors is reliable and robust. The more reliable the initial data, the more accurate the prediction model is. However, a pre-processing stage is done to handle outliers and detect sensor failures to eliminate this noise in the dataset. For this data preparation, it is also important to determine the most relevant variables to characterise the lateral car-body acceleration, which is the main purpose of this paper. Additionally, variables that are not influencing the dynamic behaviour of the train could be eliminated from the dataset in order to reduce the dimensionality of the dataset, making the optimization process of the neural network more efficient. For this purpose, a principal component analysis (PCA) is applied to the dataset. The PCA is a statistical technique to reduce the dimensionality of a dataset and determine the most relevant variables that are explaining the dataset. It is very useful in situations where large multivariate datasets are analysed.

With this technique, two principal directions are determined as linear combinations of the original data. These directions contain the most relevant information (explained variance) of the dataset. Then, original data is projected in these two principal directions to analyse the correlation between those variables graphically.

As shown in Figure 7, dynamic variables (speed and accelerations) are plotted close to each other, indicating the high correlation existing between them, whereas temperatures are plotted across the opposite direction. This is a strong indicator of the physical independence between these features. The dynamic behaviour of the train is mainly explained in the principal direction 2, due to the accelerations and speed of the train. The thermal behaviour is explained in the principal direction 1, due to all of the temperature variables registered. As a conclusion, thermal variables are discarded from the dataset, as they provide no essential information and slow down the training phase. It has been verified that including these thermal features does not improve results. As a result, in the final model of this paper, only speed and accelerations are included.

Once the data has been cleaned, the second step is to consider only data corresponding to a train speed higher than 50 km/h, because comfort degradation is mainly noticed at high speeds. Since the goal of this study is to obtain a model to learn and characterise the correct behaviour of high-speed trains in terms of comfort, it is necessary to ensure that the dataset used to train the neural network does not include samples corresponding to lack of comfort situations; however, neural networks are quite robust to outliers. In order to get the correct dataset, information regarding the anomalies (comfort loss due to excessive accelerations) suffered by the train during 2017 was collected. According to expert opinion, the samples corresponding to 15 days before the anomaly detection date were removed from the dataset. Thus, the model is inferring knowledge about good functionality of the train, and it is capable of successfully predicting this kind of situation. Hence, when the neural network predicts accelerations with high error compared to the sensor's measure, it is indicative of potential suspension or damping component failures. This is the process behind the need of predicting correct lateral accelerations to detect comfort degradation.




Figure 7. Principal Component Analysis of all the continuous variables recorded on the train.

4. Model Definition Process

In regression applications where the principal goal is the prediction of concrete values in a continuous distribution, the absolute error is commonly used to measure the cost of each iteration, expressed as: $\mathcal{L}(\hat{y}, y) = |\hat{y} - y|$. The cost function to train the model is defined, finally, as the mean absolute error (MAE):

$$J(W, b) = \frac{1}{m} \sum_{i=1}^m \mathcal{L}(\hat{y}_i, y_i) \quad (3)$$

where J represents the value for the mean absolute error (MAE), W represents the weight matrix, b represents the bias vector, m represents the number of samples in the training set (number of rows), and $\mathcal{L}(\hat{y}, y)$ represents the cost of an iteration between the real values (y) and the predicted values ($\hat{y}$).

To avoid overfitting, which is a phenomenon that occurs in automatic learning algorithms as a result of excessive training on a set of data with known results, the tendency of the model is forced to reduce the value of the weights adding a summation in the cost function. This is called regularization:

$$J(W, b) = \frac{1}{m} \sum_{i=1}^m \mathcal{L}(\hat{y}_i, y_i) + \frac{\gamma}{2m} \sum_{i=1}^L W^{[i]^2} \quad (4)$$

where γ represents the regularization parameter, which is a hyperparameter, and L represents the total number of layers in the neural network.

In this paper, L2 regularization method has been used [22]. Having defined the cost function of the model (MAE) and the regularization type, the model can be trained. In each iteration of the training phase, the trainable parameters of the ANN (w and b) are updated in the negative direction of the gradient in order to minimize the cost. To compute this gradient, it is necessary to obtain the derivatives of the cost function with respect to each trainable parameter, which are computed using the gradient descent and backpropagation algorithm [21]. Thanks to these algorithms, it is possible to efficiently reach the minimum

of the cost function and succeed in the training phase. For the backpropagation phase, multiple methods and optimizers are defined. In this paper, the Adam optimizer (Adaptive Moment Estimation) [23] has been implemented in order to decrease the training time of the model and improve its performance.

For the implementation of an ANN, it is necessary to divide the whole dataset into three sets:

1. **Training set:** used to train the ANN.
2. **Validation set:** allows the optimization of the hyper parameters of the model. Before reaching the final model, different models are analysed, so the results on this set will determine the most effective model.
3. **Test set:** the target variable (in this case lateral car-body acceleration) is removed from the test set and is used as a variable containing labels: the actual desired values. The aim of this test set is to verify that the model chosen from the validation set could be generalised to completely independent data from those used to design and evaluate the final model.
4. To evaluate the performance of each model, three performance metrics are defined:
5. **Mean Absolute Error:** a mean absolute error around 3% of the typical maximum estimated values for acceleration in the vehicle body is reflected in the EN14363 for the passenger coaches (1.5 m/s^2), which means 0.05 m/s^2 will be considered a successful result after expert consultation.
6. **Maximum error:** a maximum error between the predicted values and the labels (real values) is less than 20% of the typical maximum estimated values for accelerations in vehicle body reflected in the EN14363 for the passenger coaches (1.5 m/s^2), which means 0.3 m/s^2 will be considered a successful result.
7. **Overflow error counter:** this metric measures the percentage of data predicted with an error greater than 0.25 m/s^2 . It is important to check that there is no excessive deviation of the error, so the reliability of the model is appropriate for its purpose. If less than 1% of the data exceeds 0.25 m/s^2 (15% of the typical maximum estimated values for accelerations in vehicle body reflected in the EN14363 for the passenger coaches (1.5 m/s^2)), it will be considered a successful result.

5. ANN Models and Results

In this paper, some models have been defined with upward difficulty to compare their results and determine the most appropriate model for this real application: the prediction of lateral car-body accelerations to avoid comfort degradation and detect damping or suspension deficiencies before a service breakdown is produced. This variable is the most representative in terms of comfort (because it is directly affecting to the passengers) and failure detection in the damping or suspension system, as it is the end of the force transmission chain after the secondary suspension. It is also the variable with the highest degree of freedom.

After the data pre-processing phase described above, the remaining set has 200,000 samples used to train the neural network. In the pre-processing phase, non-reliable data and error data are removed, and data corresponding to speeds under 50 km/h are deleted as well. As previously stated in the paper, the dataset corresponds to a high-speed composition containing variables recorded every second during the year 2017. Each sample, after the cleaning up of the dataset, includes the following variables: lateral car-body acceleration (A_{yc}), vertical car-body acceleration (A_{zc}), train speed (v), and lateral wheelset acceleration (A_{yr}) for all of the 12 coaches of the trainset. There is a total number of 40 variables (A_{yc} , A_{zc} , and A_{yr} in each of the 13 axles of the coaches and the train speed). The target variable is the lateral car-body acceleration (A_{yc}) and the predictor variables are the speed (v), the vertical car-body acceleration (A_{zc}), and the lateral wheelset acceleration (A_{yr}). The input matrix X for the neural network is a (200,000; 40) dimensional matrix, and the vector containing the true values Y (used to compute the cost in each iteration) is a (200,000; 1) dimensional vector. The X columns contain the variables described above for each coach.

Before starting the training phase of the model, it is necessary to divide the dataset into three sets: training, validation, and test set. For this division, it should be considered that consecutive samples of the dataset could measure a very similar train status (acceleration values of all the coaches). A random choice of the three sets (just shuffling the dataset) would cause the separation of consecutive samples with the same acceleration values in different sets. This leads to overfitting of the model and derives in misleading results, as the model would memorize that sample but not generalise an actual behaviour. In consequence, the three sets are separated by months so there are no repeated samples in the training and validation/test sets. Moreover, 80% of the samples are used for the training set, 10% for the validation set, and the remaining 10% for the test set. After several experiments testing different architectures in the validation set of the neural network (changing hyperparameters), the final architecture defined for the model is formed by six layers (one input layer, four hidden layers, and one output layer), and 64 neurons per hidden layer.

A diagram of the neural network architecture is shown in Figure 8. As mentioned above, the neurons of every layer are fully connected through the whole architecture; however, only a few connections are shown in the figure to make it more understandable.




Figure 8. Diagram of the neural network architecture.

Overall, the model has 19,265 trainable parameters (w and b). Apart from the architecture, other parameters are set before the training phase starts. These are called hyperparameters. In this study, the tuned hyperparameters have been the learning rate and the regularization parameter. The learning rate has been set to 0.001, and the regularization parameter to 0.0001. Figure 9 shows the number of trainable parameters in each layer in the final model.

Layer (type)	Output Shape	Param #
dense (Dense)	(None, 64)	2560
dense_1 (Dense)	(None, 64)	4160
dense_2 (Dense)	(None, 64)	4160
dense_3 (Dense)	(None, 64)	4160
dense_4 (Dense)	(None, 64)	4160
dense_5 (Dense)	(None, 1)	65
Total params: 19,265		

Figure 9. Number of total trainable parameters in each layer in the final model.

The reason why the model has only six layers and 64 neurons is because making the architecture of the neural network more complex (increasing number of neurons and layers) leads to undesirable overfitting. In the obtained model, the lateral car-body acceleration of one axle is predicted using the information of the other axles. Thus, one model per train axle is needed. However, the architecture of the network and hyperparameters remains untouched for the different models.

To ensure that the trained models are good enough to solve the regression task of predicting the lateral car-body acceleration with new data, they are evaluated on the test set using the metrics that were defined before. The results of the test set evaluation are shown in Table 1. The neural network takes around 80 iterations (epochs) to converge.

Table 1. Results of the evaluation of the neural networks for each axle using the test set.

Axc.	Evaluation on the Test Set		
	Mean Absolute Error (m/s ²)	Maximum Error (m/s ²)	Overflow Error Counter (%)
Axle 1	0.0542	0.63	0.59%
Axle 2	0.0404	0.41	0.08%
Axle 3	0.0361	0.36	0.00%
Axle 4	0.0356	0.33	0.01%
Axle 5	0.0342	0.33	0.02%
Axle 6	0.0353	0.29	0.00%
Axle 7	0.0345	0.32	0.01%
Axle 8	0.0322	0.33	0.00%
Axle 9	0.0339	0.34	0.01%
Axle 10	0.0342	0.28	0.01%
Axle 11	0.0355	0.32	0.02%
Axle 12	0.0432	0.53	0.12%
Axle 13	0.0791	1.32	6.00%

Table 1 shows that, overall, the acceleration is predicted with a mean absolute error of approximately 0.03 m/s² and a maximum error of approximately 0.4 m/s², which are considered excellent results. In addition, the number of samples predicted a mean absolute error of less than 0.25 m/s², which represents the 15% of the maximum estimated values for accelerations in vehicle body indicated in the EN14363 standard. It should be noted that for axles 1 and 13, the metrics are slightly poorer. This result is expected as the end coaches are directly connected to the power heads of the train, so the mechanical guidance and connection is not as robust as between the intermediate coaches. In consequence, the

lateral movement is higher and, therefore, less predictable. However, results for axles 1 and 13 are within expected and accepted range as the error for these axles means 5.3% of the typical maximum estimated values for accelerations in vehicle body reflected in the EN 14363 for the passenger coaches (1.5 m/s^2).

In conclusion, the error margins obtained in the predictions are practically unnoticeable for the passengers in the train. This means that the algorithm is capable of detecting comfort degradation once the predictions are compared to the measured values by the acceleration sensors.

6. Model Performance in a Real Case of Application

At this stage, the optimized neural network is trained, which means its trainable parameters are static and predictions can be made by feedforwarding new information into the model. As shown before, the model achieves competitive results.

This neural network can be considered a CBM model because it is possible to achieve a constant monitorization of the accelerations in order to foresee a potential failure in the suspension and damping components.

The neural network model characterises the normal behaviour of the lateral car-body accelerations. For this reason, it is necessary to check the model's performance on data containing samples corresponding to normal dynamic behaviour and other samples corresponding to comfort degraded behaviour (high lateral acceleration values). Theoretically, the model should not predict accelerations corresponding to train comfort degradation with the same accuracy as it does for normal accelerations. In order to prove this idea, a completely new dataset is introduced into the neural network, and the prediction results are evaluated. This new dataset contains around 10,000 samples and the same variables as before (train speed and accelerations for each axle), but it corresponds to a different year than the one used for training. This data was recorded in 2019, when a passenger sitting on the 11th coach of the train noticed an excessive lateral car-body displacement during his trip, causing a loss of comfort. As the typical maximum estimated values for accelerations in vehicle body reflected in the EN 14363 for the passenger coaches (1.5 m/s^2) was far from being reached, the safety alerts were not triggered. However, a clear comfort degradation was detected, and a specific maintenance inspection was programmed to check damping and suspension elements of this coach. Indeed, one damper had to be replaced, so a technical reason for this situation was discovered.

The results obtained after predicting the lateral car-body accelerations for this specific dataset are shown in Table 2.

As it is stated in Table 2, predictions are extremely accurate for accelerations corresponding to axles 1 to 9. This means that those axles are within the expected range of lateral acceleration values corresponding to normal behaviour, so the model performs correctly. However, for axles 10 to 13, predictions are extremely poor. The model has a mean absolute error of around 0.4 m/s^2 in the predicted accelerations for those axles, and it foresees more than 60% of the data with an error greater than 0.25 m/s^2 (15% of the typical maximum estimated values for accelerations in vehicle body reflected in the EN 14363 for the passenger coaches (1.5 m/s^2)). Considering that comfort degradation was detected in the 11th coach of the train (leans over axles 10 and 11), the model is validated as the results perfectly describe the situation.

This is a clear example of a situation in which a comfort loss that derived in a damaged component and its replacement was not detected by the current system. Results have proved that if this model was implemented, the potential damage could have been foreseen and the system could have been correctly adjusted instead of directly being replaced. This model can, therefore, extend the service life of some components in the train and contribute to creating a more sustainable line of maintenance. Moreover, the implementation of this model in the train will enable the monitorization of the difference between the measured lateral acceleration values and the predictions of the neural network. A feasible CBM model is then achieved for this train series.

In Figure 10, lateral car-body predicted accelerations and real accelerations of axle number 5 are plotted: the real values are represented in blue, and predicted values are represented in red. No relevant differences between the prediction and the real values are detected, so the model perfectly predicts good behaviour of axle number 5.

Table 2. Results of the model evaluation of the new dataset.

Ayc	Evaluation on Real Case of Application of 2019		
	Mean Absolute Error (m/s ²)	Maximum Error (m/s ²)	Overflow Error Counter (%)
Axle 1	0.0611	0.79	1.56%
Axle 2	0.0518	0.47	0.07%
Axle 3	0.0251	0.26	0.00%
Axle 4	0.0217	4.77	0.02%
Axle 5	0.0263	5.16	0.00%
Axle 6	0.0379	4.95	0.00%
Axle 7	0.0354	0.41	0.01%
Axle 8	0.0523	4.69	0.10%
Axle 9	0.0634	4.91	0.08%
Axle 10	0.2321	5.08	49.8%
Axle 11	0.6467	4.88	75.1%
Axle 12	0.3523	4.97	62.0%
Axle 13	0.1162	5.01	10.2%




Figure 10. Lateral car-body accelerations (vertical axis) of axle number 5 versus time (horizontal axis): real values in blue, and predicted values in red.

On the other hand, in Figure 11, lateral car-body predicted accelerations and real accelerations of axle number 11 are plotted. A significant difference between the predicted values and the real values is detected, exceeding the established limits of normal behaviour of the lateral movement of the train. In this sense, a clear comfort degradation is detected in the same axle in which the passenger that alerted of the excessive lateral movement was seated.

The above defined model is focused on predicting lateral car-body acceleration of one coach considering the rest of the variables and the behaviour of the rest of the coaches. However, this predictive model can be extrapolated to other dynamic variable prediction (other accelerations or bearing temperatures, for example), reaching similar results and same satisfactory performance. In particular, it can be adapted to predict not only lateral car-body accelerations (Ayc) but also vertical accelerations (Azc), obtaining a mean training error of 0.029 m/s². Moreover, this model also is valid for the entire fleet. For other trainset models, minor adjustments should be implemented to assure the most optimized algorithm. The mentioned flexibility of the model to perform successfully in these situations is based on

two factors: the neural network models' robustness, and the similar technical characteristics of the dynamic behaviour of any train. On one hand, Artificial Neural Networks are one of the most robust Machine Learning algorithms when it comes to performing on similar tasks. This is because the regularization methods permit the algorithm not to overfit the data and reduce the variance of the model, allowing the neural network to generalise the dynamic behaviour of the train, but not only for this specific group of training data [24]. In this paper, the L2 regularization method has been used to train the model, being flexible to slightly different data inputs [25]. On the other hand, similarity between the dynamic behaviour of high-speed trains considering the same suspension and damping design concept makes the trained model applicable to other high-speed trains. The robustness and reliability of the data recorded to be used for training algorithms is fundamental for good model creation and optimization, so reliable electronics and sensors are required for obtaining optimized results.




Figure 11. Lateral car-body accelerations (vertical axis) of axle number 11 versus time (horizontal axis): real values in blue, and predicted values in red.

7. Contribution to Sustainable Maintenance

This paper contributes with the evolution to a predictive maintenance and CBM concept and, consequently, to a more sustainable maintenance strategy of the railway systems. If most of the important failures during operation are avoided, and real-time monitored information is treated to adapt to the maintenance inspections required by the train, a clear optimization of the resources will be reached: preventive maintenance stops will be reduced, corrective operations will decrease, and extra displacements of the trains will be eliminated, reducing the use of energy, human, and material resources, and creating an energy efficient model. The state-of-the-art is creating the future idea of a sustainable maintenance model focused on a “none-maintenance” concept, where the train is responsible for visiting maintenance depots only when it is clearly needed, and in those cases where prescriptive or predictive maintenance are not able to definitively solve the detected problem.

Extrapolating this concept to the entire fleet, a global fleet train management architecture will assure this positive contribution to the social, environmental, and economic compromise aligned with the European objectives stated for 2030.

8. Conclusions

The main objective of this paper is reached: obtaining a CBM model through a neural network model capable of predicting the lateral car-body accelerations for the comfort degradation monitoring and the identification of damping or suspension potential failures. An optimized neural network and a demonstration of its satisfactory performance with a real case of application have been determined.

Firstly, comfort degradation monitoring is achieved in the sense that a real-time implementation of the neural network allows one to compare the predictions of the model (ideal behaviour) and the sensor measurements (real behaviour). In this way, it is possible to identify comfort losses if the difference between both values starts progressively increasing.

Secondly, potential failures in dynamic train components are identified as the neural network model predicts abnormal behaviour of lateral car-body accelerations. Frequently, abnormal accelerations respond to unusual behaviour of these components, so an inspection can be programmed preventively to avoid potential damages or to correct failures detected that could derive in higher damages during operation, such as loose screws or supports, worn fixations, damper's oil degradation, etc.

Considering the technical implementation of the algorithm, an important fact is that training the model only taking into account the dynamic variables of the train is profitable. This implies reducing computing times, obtaining almost the same error rates; thus, a computational cost reduction is identified. This conclusion was also evidenced in the PCA statistical analysis.

The good performance of the model is demonstrated in two different results:

1->The mean absolute error obtained is 0.034 m/s², which is less than 3% of the typical maximum estimated values for accelerations in vehicle body reflected in the EN 14363 for the passenger coaches (1.5 m/s²), which is considered a successful result.

2->The number of predictions with errors greater than 0.25 (as it is the 15% of the typical maximum estimated values for accelerations in vehicle body reflected in the EN 14363 for the passenger coaches (1.5 m/s²)) is quite low: 12 times in the training phase and 5 times in the test phase. Considering a total amount of 140,000 training samples and 30,000 test samples, approximately, in less than 1% of the samples, the limit is exceeded, acting as an important indicator for the good performance of the model.

However, further evidence of the success of the results is the real application case where the comfort degradation detected by a passenger was perfectly identified by the model: a mean absolute error of 0.6467 m/s² and an overflow error counter of 75.1% far exceeded the proposed limits. Therefore, this model could be implemented in the context of condition-based maintenance: in case of detecting a deviation of normal behaviour, an alarm will be sent to the fleet management system. The meaning of this alarm is a comfort degradation detection or a potential failure of the suspension or damping system, so a specific maintenance stop could be programmed in advance to correct this situation before the incident occurs.

In summary, an optimal CBM model for detecting comfort degradation and premature suspension or damping system failures is obtained with successful results considering mean errors of less than 0.04 m/s², which means unnoticeable values for passengers.

The state-of-the-art ensures safety in high-speed trains, but there is no constant monitoring of the comfort status in the train to assure the best comfort levels to passengers as proposed in this paper in order to contribute to user experience. This methodology is also aligned with a sustainable maintenance model considering the energy efficiency concept and the optimization of environmental resources.

Author Contributions: Conceptualization, P.G.M.-L.; methodology P.G.M.-L.; Á.S.J. and J.G.S.; software, Á.S.J. and J.G.S.; validation, P.G.M.-L. and Á.S.J.; formal analysis P.G.M.-L.; investigation, P.G.M.-L.; resources, P.G.M.-L.; J.d.D.S.B.; Á.S.J. and J.G.S.; data curation, Á.S.J. and J.G.S.; writing—original draft preparation, P.G.M.-L. and Á.S.J.; writing—review and editing, P.G.M.-L. and Á.S.J.; visualization, Á.S.J. and J.G.S.; supervision P.G.M.-L. and J.d.D.S.B.; project administration, P.G.M.-L. and J.d.D.S.B. All authors have read and agreed to the published version of the manuscript.

Funding: This research received no external funding.

Institutional Review Board Statement: Not applicable.

Informed Consent Statement: Not applicable.

Data Availability Statement: Not applicable.

Conflicts of Interest: The authors declare no conflict of interest.

References

1. DIN EN 14363:2016-10. In *Railway Applications—Testing and Simulation for the Acceptance of Running Characteristics of Railway Vehicles—Running Behaviour and Stationary Tests*; CEN Brussels: Bruxelles, Belgium, 2016.
2. Garrido, P. *Modelo de los Efectos no Lineales de Amortiguadores Transversales en Bogies Ferroviarios*; Universidad Politécnica de Madrid: Madrid, Spain, 2016.
3. Filip, A.; Beugin, J.; Marais, J.; Mocek, H. *COMPRAIL: Safety Concept of Railway Signalling Based on Galileo Safety-of-Life Service*; WIT Press: Toledo, Spain, 2008.
4. Azim, R.; Gül, M. Damage Detection of Steel Girder Railway Bridges Utilizing Operational Vibration Response. *Struct. Control Health Monit.* **2019**, *26*, e2447.
5. Song, Y.; Wang, Z.; Liu, Z.; Wang, R. A spatial coupling model to study dynamic performance of pantograph-catenary with vehicle-track excitation. *Mech. Syst. Signal Process.* **2021**, *151*, 107336. [\[CrossRef\]](#)
6. Zhai, W.; Wang, K.; Cai, C. Fundamentals of vehicle-track coupled dynamics. *Veh. Syst. Dyn.* **2009**, *47*, 1349–1376. [\[CrossRef\]](#)
7. Zheng, S.; Zhong, Q.; Chai, X.; Chen, X.; Peng, L. A Novel Prediction Model for Car Body Vibration Acceleration Based on Correlation Analysis and Neural Networks. *J. Adv. Transp.* **2018**, *2018*, 1752070. [\[CrossRef\]](#)
8. Kun, Q.; Jie, L.; Yin-han, G. The prediction of vibration and noise for the high-speed train based on neural network and boundary element method. *J. Vibroeng.* **2015**, *17*, 4445–4457.
9. Sadeghi, J.; Khajehdezfuly, A.; Heydari, H.; Jones, M.; Poggio, T. Development of railway ride comfort prediction model: Incorporating track geometry and rolling stock conditions. *ASCE J. Transp. Eng.* **2020**, *146*, 04020006. [\[CrossRef\]](#)
10. Sadeghi, J.; Rabiee, S.; Khajehdezfuly, A. Development of railway ride comfort prediction model for railway slab track system. *Lat. Am. J. Solids Struct.* **2020**, *17*, e304. [\[CrossRef\]](#)
11. EN 12299:2009-08. *Railway Applications—Ride Comfort for Passengers—Measurement and Evaluation*. Available online: <https://www.beuth.de/en/standard/din-en-12299/117755875> (accessed on 6 November 2021).
12. Bruno, J.A. Costa, Rodolfo Martins, Magno Santos, Carlos Felgueiras, Rui Calçada. Weighing-in-motion wireless system for sustainable railway transport. *Energy Procedia* **2017**, *136*, 408–413.
13. Khodabandehlou, H.; Pekcan, G.; Fadali, M.S.; Salem, M.M.A. Active neural predictive control of seismically isolated structures. *Struct. Control Health Monit.* **2018**, *25*, e2061. [\[CrossRef\]](#)
14. Kans, M.; Galar, D.; Thaduri, A. *Proceedings of the 10th World Congress on Engineering Asset Management (WCEAM 2015)*; Springer: Cham, Switzerland, 2016.
15. Bye, R. Designing mobile user experiences: Disruptive innovation in railway asset information. In *Rail Human Factors: Supporting Reliability, Safety and Cost Reduction*; CRC Press: Boca Raton, FL, USA, 2013; Volume 453, ISBN 9781138000377.
16. Santos, J.P.; Crémona, C.; Calado, L.; Silveira, P.; Orcesi, A.D. On-line unsupervised detection of early damage. *Struct. Control Health Monit.* **2016**, *23*, 1047–1069. [\[CrossRef\]](#)
17. Farahani, B.V.; Barros, F.; Sousa, P.J.; Tavares, P.J.; Moreira, P.M.G.P. A railway tunnel structural monitoring methodology proposal for predictive maintenance. *Struct. Control Health Monit.* **2019**, *27*, e2587.
18. Daily, J.; Jeff, P. Predictive maintenance. In *Supply Chain Integration Challenges in Commercial Aerospace*; Springer: Cham, Switzerland, 2017.
19. He, K.; Zhang, X.; Ren, S.; Sun, J. Delving Deep into Rectifiers: Surpassing Human Level Performance on ImageNet Classification. In *Proceedings of the 2015 IEEE International Conference on Computer Vision (ICCV15)*, NW Washington, DC, USA, 7–13 December 2015; pp. 1026–1034.
20. Glorot, X.; Bengio, Y. *Understanding the Difficulty of Training Deep Feedforward Neural Networks*; AISTATS: Vancouver, QC, Canada, 2010; Volume 9.
21. Rojas, R. The Backpropagation Algorithm. In *Neural Networks*; Springer: Berlin/Heidelberg, Germany, 1996.
22. Jolliffe, I. Principal Component Analysis. In *Encyclopedia of Statistics in Behavioral Science*; Everitt, B.S., Howell, D.C., Eds.; Springer: New York, NY, USA, 2005.
23. Kingma, D.P.; Ba, J. Adam: A Method for Stochastic Optimization. In *Proceedings of the International Conference on Learning Representations (ICLR)*, San Diego, CA, USA, 7–9 May 2015.
24. Girosi, F.; Jones, M.; Poggio, T. Regularization Theory and Neural Networks Architectures. *Neural Comput.* **1995**, *7*, 219–269. [\[CrossRef\]](#)
25. Van Laarhoven, T. L2 Regularization versus Batch and Weight Normalization ArXiv abs/1706.05350 (2017). *arXiv* **2017**, arXiv:1706.05350.

Application of neural networks for the prediction of railway bearing failures

Pablo Garrido Martínez-Llop , Juan de Dios Sanz Bobi and Alberto Huera Plaza

Proc IMechE Part F:
J Rail and Rapid Transit
2022, Vol. 236(10) 1147–1153
© IMechE 2022
Article reuse guidelines:
sagepub.com/journals-permissions
DOI: 10.1177/09544097221084419
journals.sagepub.com/home/pif

Abstract

Bearing overheating and anomalous accelerations are two principal failure modes for this safety component. The supervision of bearing's behaviour is essential to ensure a safe and reliable operation. A safety component's failure may cause a speed limitation or even a non-available train for operating, so a predictive maintenance for bearings and other critical components is mandatory for the manufacturers, operators and maintainers in the railway sector. Bearing temperature, exterior temperature, train speed and other variables are measured every second in real time. From all the data collected and stored in the last years some algorithms and models are designed and trained in this paper to detect bearing anomalies 2 days before a real failure is detected and the safety alarm is enabled. The methodology for obtaining the optimal algorithm is exposed. Different artificial neural networks based on different optimization models such as the Mini-batch Gradient Descent (MGD) or Adam optimizer are compared. A final neural network with 10 hidden layers to detect bearing failure is proposed reaching 99% of accuracy, 95% of precision and 90% of sensitivity. The objective of predicting a bearing anomaly with some days in advanced is reached with high precision level, which will lead also to cost savings and a contribution for the sustainability because many inspections could be reduced and the energy cost associated to them.

Keywords

Machine learning, deep learning, predictive maintenance, artificial neural networks, railway safety, railway reliability, mini-batch gradient descent, bearing anomalies

Date received: 21 April 2020; accepted: 14 February 2022

Introduction

Every system operating in an industrial environment requires a high degree of reliability, availability, maintainability and safety (RAMS). Without any doubt, since the very beginning of the railway industry, safety has always been the most important fact to consider. At the present time, sufficient safety level is implemented in the trains based on the standards, directives or other regulations, so it is considered that this fact is deeply studied and implemented. For this reason, reliability, availability and maintainability are increasingly becoming more important for railway manufacturers, operators and maintainers, as it is also directly related with the operational costs.

A failure during operation of any important component of the train (that affects not only to safety but also to reliability)¹ could lead to a clear loss of productivity or quality service suffered during the process of repairing the damaged element, the labour required and the cost of replacement. Moreover, additional indirect costs might also be considered such as possible damage to third parties, financial penalties for civil or penal liability or the negative impact on the corporative image of the responsible company. As an example, a failure in the heating ventilation air conditioning (HVAC) system penalizes passenger's comfort in the train during the journey, and the operator shall

reward the passengers as a penalty for the lack of comfort. Other representative example that affects reliability but also safety is an alarm of bearing overheating. In that case, a speed limitation is applied or even useless train is declared, so operator or manufacturer might incur in high penalties for the delay produced.

In the last few years, public railway tenders are demanding high reliability and availability values so traditional fleet management and preventive maintenance approach are not valid any more to comply with the operator's requirements. The new scenario needs to take advantage of the new technologies by redirecting the operation to zero failures and minimum maintenance stops and inspections. A similarity could be made with the aeronautic sector, where the aircrafts downtime is reduced as much as possible. Requirements related to the availability of the trainsets are close to 100% in the last years. These requirements include all the safety functions and also

Department of Mechanical Engineering, Universidad Politécnica de Madrid University, Madrid, Spain

Corresponding author:

Pablo Garrido Martínez-Llop, Department of Mechanical Engineering, Universidad Politécnica de Madrid, c/ José Gutiérrez Abascal, 2, Madrid 28006, Spain.
Email: pgmll252@gmail.com

functionalities that under degraded mode could cause any operational limitation: loss of redundancies, not all HVAC systems working properly, a loss of traction effort. If any of these functionalities are not working properly, an operational limitation could be applied and then the train availability will be affected.

Consequently, maintenance concept has evolved from the traditional corrective maintenance to the preventive, predictive and actually prescriptive maintenance, which is still being developed as part of the Industry 4.0 context.²

For optimizing maintenance process, predictive maintenance is developed. An optimization of resources is reached through the identification of anomalies and failure patterns in order to provide alerts when a component is coming to the end of its life in operation or to a previously identified failure mode. It is necessary to identify physical variables whose variation is related to the appearance of failures, and it also requires a broad knowledge of the mathematical and physical models that govern the process, as well as the availability of sufficient computational means to address the solution. A good implementation of predictive maintenance will surely cause clear economic benefits^{3,4} as well as a considerable contribution of the energy saving and efficiency which is aligned with a sustainable transport concept.

In this paper, different artificial neural networks will be developed and compared with the aim of predicting bearing failures. A methodology of the process to obtain the optimal model is presented. In this study, non-time series are considered so the prediction is based on the interrelation between all the variables measured on real time around the bearing. The time dependence in this study of bearing temperatures is not as relevant as the relationship between the different physical variables measured in each second due to the thermal inertia of these components. The methodology followed and the results obtained could be useful to implement the artificial neural network in the on-board control electronics, as part of the predictive maintenance strategy in the global concept of the maintenance of a train.

Theoretical base

An artificial neural network (ANN) is a computer model based on a set of simple, constructively identical nodes, called artificial neurons or perceptrons. These perceptrons are grouped in layers, so that all the perceptrons in one layer are connected to all the perceptrons in the next layer, allowing the transmission of information between layers of ANN. The name comes from the idea of imitating the functioning of the neuronal networks of living organisms. Figure 1 shows the structure of a biological neuron compared with an artificial neuron used in machine learning algorithms:

Each neuron is characterized by the following parameters: w_i (weight) and b (independent term). Figure 2 shows the structure of an artificial neuron.

The inputs or activations received are subjected firstly to a linear operation, and secondly to a non-linear operation.




Figure 1. Structure of a biological neuron.




Figure 2. Structure of an artificial neuron.

As can be observed in Figure 2, in linear operation, the independent weights and terms learned by the model are used according to the expression

$$z = \sum_i (w_i \cdot a_{i-1}) + b \quad (1)$$

The non-linear operation or activation phase is implemented by ReLU and sigmoid functions. In turn, each neuron could be contained within three different types of layers: input layer, hidden layers and output layer. The number of hidden layers in a neural network depends on the problem to be solved, and is a hyper parameter of the model that must be optimized to maximize the accuracy of the model. A high number of layers implies a more deep and complex neural network.

Methodology

In this paper, a research of bearing temperatures behaviour is carried out in order to define different models capable of predicting in advance a failure of this component in a specific train series.

The study is approached as a binary classification problem in which the bearings should be classified as healthy bearings (class 0) or faulty bearings (class 1). Based on a multilayer perceptron (MLP), the number of neurons in each layer and the number of hidden layers in the network will be progressively increased. Likewise, several improvements are introduced on the model optimization algorithms that improve its performance in comparison with previous models. These improvements require the adjustment of new hyper parameters in the model, increasing the complexity and the time needed to train the model's parameters until it converges to a solution.

The ANN learning process which is applied to the training set can be subdivided into the following phases:

initialization of the model parameters, where He normal initializer⁵ and Glorot normal initializer⁶ have been used; forward propagation, where sigmoid functions are widely used for classification problems; cost estimation for evaluating the performance of the algorithm; backward propagation and update of the model parameters to continue reducing the cost function and consequently the error to obtain an optimized model after certain number of iterations.

Data analysis and model definition process

The first step is to acquire, process and filter the data in order to work with a reliable and robust data set. For this purpose, data vectors for each instant of time of every wheel axis belonging to a train have been collected. Each vector contains the following variables: exterior temperature (v_1), train speed (v_2), bearing temperatures (v_3 - v_6 , two bearings per wheel) and brake pressure (v_7). In addition, to increase the samples and have a significant number of data, a group of trainsets of a particular train series is studied.

In the following figure, it is represented the distribution of the bearings and accordingly the bearing temperature sensors in one wheel axis. Each wheel axis contains two wheels with two bearings per wheel: one interior bearing and one exterior bearing: [Figure 3](#)

A very high linear correlation between the measured variables (7) is expected. For example, a high exterior temperature or high speeds on straight track sections will result in higher temperatures in the bearings. Similarly, the application of high braking pressure will cause friction and in turn heat dissipation to the bearings, increasing the temperature of these components.

Initial data treatment is essential to warranty a robust solution of the problem. The more reliable the initial data, the more accurate the prediction model designed. Sensor errors, unreliable data, impossible cases and recurrent outliers seriously impair model performance and for these this reason should be removed from the samples. As an example, the following cases are eliminated for the study: data considering 255° temperatures which means sensor electrical connection failure, data considering 0 km/h as train speed so the train is stopped in a station or at depot due to maintenance inspections so there are not representative samples of bearings working in daily train operation.

Once the data has been cleaned, other aspects need to be checked such as the imbalance between the sample quantity belonging to both classes (0 and 1) is not excessive. This is because the class will contribute to the cost function, and therefore to the components of the gradient, in the same proportion as the examples belonging to that class.

In binary classification applications, one of the most common functions is the cross entropy cost function. Due to the nature of the problem, much more data is available on the healthy behaviour of bearings in service (class 0), than faulty bearings (class 1). To mitigate the problem, a final hyper parameter (δ) has been implemented in the cost function to adjust manually the contribution of each class in the cost function as follows




Figure 3. Bearings and sensors distribution in one wheel axis.

$$L(y, \hat{y}) = \left[-\delta \cdot y^{(i)} \cdot \log \hat{y}^{(i)} - (1 - y^{(i)}) \cdot \log (1 - \hat{y}^{(i)}) \right] \quad (2)$$

This adjustment must be done carefully to avoid producing an excess of false positives (classify healthy bearings as faulty bearings).

To avoid overfitting, which is a phenomenon that occurs in automatic learning algorithms as a result of excessive training on a set of data with known results, the tendency of the model is forced to reduce the value of the weights from the cost function adding a summation in the cost function

$$J(W, b) = \frac{1}{m} \cdot \sum_{i=1}^m L(y, \hat{y}) + \frac{\lambda}{2m} \sum_{i=1}^L W^{[l]^2} \quad (3)$$

After the backward propagation phase, the model parameters are updated. For this last phase, multiple methods and optimizers are defined. In this paper, a very simple algorithm has been used initially: the gradient method. Subsequently, a more complex optimizer such as the Adam optimizer⁷ (Adaptive Moment Estimation) has been implemented in order to decrease the training time of each model, iterating with greater speeds through different neural network architectures.

For implementing the ANN it is necessary to define three sets:

1. **Training set:** used for training the ANN. Some faulty cases are identified (class 1) and much more healthy cases are available (class 0).
2. **Validation set:** allows the optimization of the hyper parameters of the model. As different models are proposed, the results on this set will determine the most effective model.
3. **Test set:** verifies that the model chosen from the validation set could be generalised to completely independent data from those used to design and evaluate the final model.

In a binary classification problem, the results are classified as positive (p/1) or negative (n/0). The predictions made can be grouped into four cases: true positives (the result of the prediction is 1 and the actual value is 1), false positives (the result of the prediction is 1 and the actual value is 0), false negatives (the result of the prediction is 0 and the actual value is 1) and true negatives (the result of the prediction is 0 and the actual value is 0).

One of the indicators to evaluate the effectiveness of the model is the accuracy, which is defined as

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (4)$$

If in the training set the ratio between the two classes is very different, the accuracy cannot be considered representative of the estimator's fitness. Since in this study there are many more samples of the negative class than the positive class, it is necessary to find other indicators to evaluate the model

$$Precision = \frac{TP}{TP + FP} \quad (5)$$

$$Sensitivity \text{ or } recall = \frac{TP}{TP + FN} \quad (6)$$

Precision is defined as the probability that a positive prediction will turn out to be positive, while sensitivity represents the percentage of positive cases that have been identified as such. These indicators are much more useful to evaluate the model and the ideal case is achieved when both values are 1. A specific indicator called F1 score is also defined to evaluate the correlation between precision and recall in a model. In our application a high value of precision is more relevant than recall. It is very important to identify the true positives always and reduce the false positives because an extra cost for the inspection is incurred. A true positive means an imminent failure of a safety element (bearing) so it is preferable to obtain false positives than false negatives. All failures must always be detected in advance.

Finally, to reduce bias and variance of the models,⁸ the number of hidden layers is increased and the regularization process is developed so the mitigation of these two concepts is assured.

ANN models and results

In this study, some models have been defined with upward difficulty to compare the results and determine the most appropriate model for this real application: detecting faulty bearings before a service breakdown is produced. A table with bearing incidents during commercial service is available so a supervised model is proposed. There are few cases of failure in comparison with the healthy cases as expected, but different alternatives to correct this issue are implemented in the models. All data from the coach 48 h before the failure's detection is classified as faulty bearing (class 1). These failures detections are obtained from the maintenance registers once the bearings have been removed and quality department has confirmed a real failure. After the data pre-processing phase, 1.503.627 training examples are obtained: 127.430 examples belong to defective bearings and 1.376.397 to bearings that are in good condition. The result is an X data matrix (model input) of dimensions (1.503.627 7) with a corresponding Y data matrix (model output) of dimensions (1.503.627 1). The X columns contain the following information, from left to right: exterior temperature (v1), train speed (v2), bearing temperatures (v3-v6, two bearings per wheel) and brake pressure

(v7). Due to computation limitation a reduction to 200.000 examples is applied, in a 1:1 ratio, by randomly selecting 100.000 data from class 0 and 100.00 data from class 1, since the model does not need to consider time dependence. A 90% of this example will be used for the training set, a 5% for the validation set and the remaining 5% for the test set. This set size is based on expert criteria and recommendations.⁹

All the models exhibited have been trained once the learning rate has been optimized, which is one important hyper parameter to be optimized in the different models.

Model 1 with 1 hidden layer

Hyper parameters: layer dimension (7, 300, 1); learning rate of 0.5×10^{-6} ; regularization parameter 0.03 and number of iterations 10.000.

Conclusion: The algorithm is saturated almost from the beginning of the training phase and is not able to learn anything else. The chosen architecture does not have enough parameters to be able to learn the complexity of the information contained in the supplied data set. It is observed that the accuracy of the model is less than 50%, so it is worse than an estimator that randomly generates a 0 or a 1 for each sample. This is because the algorithm predicts $y = 1$ (defective bearings) for the vast majority of case. It is necessary to increase considerably the number of hidden layers in the model in order to correct the severe bias problem. [Figure 4](#)

Model 2 with 3 hidden layers

Hyper parameters: layer dimension (7, 50, 50, 50, 1); learning rate of 0.1×10^{-4} ; regularization parameter 0.03 and number of iterations 10.000.

Conclusion: The results are better in terms of accuracy and precision than the single-layer model with 300 neurons, but still not much better than an estimator that predicts 0 or 1 at random. The model starts making predictions based on the input values instead of predicting in the same vein all the time. Little variance is appreciated, but bias is still very high, so the complexity of the model needs to be increased. [Figure 5](#)

In general, for the same total number of neurons in the network, the accuracy of the model will increase with the number of hidden layers until sufficient complexity is reached for the model to learn all the information contained in the data. This is because the activations received by the last layers have passed through a greater number of non-linear activation functions, so that the complexity of the functions learned by the model is exponentially greater. This is demonstrated in [Figure 9](#) where the total number of neurons is 301, with the same number of hidden layers. [Figure 6](#)

Doubling the number of neurons per layer results in a significant increase in accuracy, in addition to exceeding the 50% in precision. In other words, more than one out of every two positives detected by the system will be true. Despite the improvement, it is believed that the bias is still reducible, so layers will continue to be added. After almost 400 iterations the model enters a saturation state.




Figure 4. Model 1: Cost over iterations, results of training set and results of validation set.




Figure 7. Model 3: Cost over iterations, results of training set and results of validation set.




Figure 5. Model 2: Cost over iterations, results of training set and results of validation set.




Figure 6. Model 2 with 301 neurons: Cost over iterations, results of training set and results of validation set.

Model 3 with 6 hidden layers

Hyper parameters: layer dimension (7, 250, 250, 250, 250, 250, 1); learning rate of 0.5×10^{-4} ; regularization parameter 0.03 and number of iterations 2.000.

Conclusion: The results of this model show that a proper algorithm is capable of detecting up to 90% of data that have been labelled as faulty. The false negatives detected correspond to very low speeds of the train or even with no braking pressure, which means that during acceleration of the train is difficult to detect a faulty bearing due to the particular behaviour of the thermal inertia. Some of the false negatives are (26, 7, 25, 27, 26, 25, 0) (speed of 7 km/h and no braking pressure) and (15, 11, 15, 17, 17, 16, 0) (speed of 11 km/h and no braking pressure). [Figure 7](#)

With six hidden layers, the complexity of the model begins to be high enough that the bias of the system begins to approach the minimum value for the data used. An improvement is detected in terms of sensitivity and accuracy. However, increasing the number of hidden layers above this amount has not been associated with an increase in model efficiency.

The high proportion of false positives (~40%) will be reduced significantly by including a larger number of samples of bearings in good condition.

Conclusions for models 1, 2 and 3

- The estimator is able to detect patterns in the thermal profiles and correlate them with the existence of defective bearings without taking on account the time series character of the data.
- A model with 6 or 7 hidden layers allows the extraction of most of the available information.
- The model is capable of achieving high percentages of precision and sensitivity, (~80% and ~90% respectively) although not simultaneously.
- Precision and recall have significantly decreased when evaluated on the totality of the filtered data compared to the values obtained on the training and validation sets. A bias problem is detected and will be corrected by adding more cases of bearings in good condition ($y = 0$).
- The accuracy is maintained at very high values, even higher than those obtained in the training and validation set.

A new, larger data set is defined to train a new model to correct for the high rate of false positives in the current model. Bias problem and optimization of the binomial precision and sensitivity is implemented in the following models.⁸

Model 4 based on Adam optimizer⁷

A total of 1,639,743 samples are studied in this model: 127,430 correspond to defective samples and the remaining 1,512,313 belong to bearings in good condition. These samples have been randomly distributed over the training, validation and test sets in a 90:5:5 ratio.

The previous optimization algorithm, the Batch Gradient Descent (GD), is replaced by the Mini-batch Gradient Descent (MGD). The MGD differs from the GD¹⁰ in which it takes fixed and undersized batches of the data set to train the model. Therefore, a larger number of samples can be trained although another hyper parameter is defined.

Hyper parameters: layer dimension (7,100,100,100,100,100,100,100,1); learning rate of 0.3×10^{-4} ; regularization parameter 0.1; number of epochs 500 and mini-batch size 512.

Conclusion: A considerable improvement is observed in accuracy and F-value compared to previous models, due to the incorporation of a large amount of samples of bearings that are in good conditions. Precision is also improved and consequently false positives are reduced. The recall value reached is also acceptable. [Figure 8](#)




Figure 8. Model 4: Cost over iterations, results of training set and results of validation set.




Figure 9. Model 5: Cost over iterations, results of training set and results of validation set.

Model 5 final model

Lastly, the final model with 10 hidden layers is presented with slight changes in some of the hyper-parameters so the most optimal model is defined, with the best F-value reached.

Hyper parameters: layer dimension (7,100,100,100,100,100,100,100,100,1); learning rate of 0.3×10^{-4} , regularization parameter 0.1 ; number of epochs 500 and mini-batch size 512.

Conclusion: High values of accuracy and precision are reached. An improvement in the recall is observed (90%) and F-value obtained is the most optimal. [Figure 9](#)

Defining a larger data set improves significantly the accuracy, precision and recall of the algorithm. It is increased from 8 (model 4) to 10 hidden layers (model 5) because a slight improvement is observed. It is been proven that a higher number of hidden layers is not enhancing the model. The same situation is observed with the other hyper parameters such as number of neurons, learning rate and regularization parameter. Further improvements are insignificant compared with the computational cost or the real final application of the algorithm.

Finally, a final optimized model is achieved (model 5), obtaining an accuracy of 99%, precision of 95% and a recall of 90%, which implies a good algorithm with high performances to detect bearing failures in railway application.

Conclusions

The first models were essential to have an approach of the appropriate values for the hyper parameters such as the number of hidden layers, number of iterations...

The final model is capable of reaching best F-values, which implies high precision and recall simultaneously (95% and 90%, respectively). This characteristic was not achieved in models based on the gradient method. The

model is also able to maintain approximately the same effectiveness on the test set as on the validation and training sets.

As can be deduced from the results obtained in this paper, the most influential hyper parameter in the effectiveness of the model is the number of hidden layers in the model, followed by the number of neurons per layer.

On the other hand, the sampling time of the sensors (1 or 2 seconds) is relatively small compared to the setting times of the thermal transients. This thermal inertia leads to many similar or redundant samples, so that it is not necessary to use a very high adjustment parameter, as there is little variance in the data for the same type of failure.

The main conclusion that could be drawn from this paper is that it is possible to differentiate between faulty bearings and those in good condition, predicting with high precision whether the bearing will fail in the next 2 days by correlating the temperature profile in the bearing with other variables such as the outside temperature, the speed of the train at that moment and the braking pressure. Due to the way in which the data acquisition is carried out, it has not been possible to take into account the time series character of the data. But the interest of this study lies in the fact that it is possible to detect bearing failures without taking into account the time series directly.

Accuracy (~99%), precision (~95%) and recall (~90%) obtained, are exceptionally high, considering that this is the first approach to the predictive maintenance task of this component. So far, bearings have simply been removed when the failure has already occurred or when the bearing over-temperature alarm is activated, which does not mean that the bearing is necessarily defective. Many false positives are detected on a daily operation.

With the final model proposed, a high improvement is obtained in terms of predicting bearing failures. The number of defective bearings detected during commercial service will be considerably reduced because a failure prediction is implemented at least 48 h in advance. The rate of false alarms (false positives) will decrease with the consequent economic savings as a direct consequence of avoiding unnecessary removal of healthy bearings.

This model will be implemented in one of the train control electronics. Once a total of 1000 defective bearing warnings is accumulated in less than 2 h, an alarm will be sent to the fleet management system. If 5.000 warnings are received in less than 24 h the train will be sent to depot directly due to an imminent safety failure of the bearing.

Declaration of conflicting interests

The author(s) declared no potential conflicts of interest with respect to the research, authorship, and/or publication of this article.

Funding

The author(s) received no financial support for the research, authorship, and/or publication of this article.

ORCID iD

Pablo Garrido Martínez-Llop  <https://orcid.org/0000-0002-4851-1737>

References

1. Garrido P. «*Modelo de los efectos no lineales de amortiguadores transversales en bogies ferroviarios*». Thesis (Master thesis). *E.T.S.I. Industriales (UPM)*, 2016.
2. Ciocoiu L, Siemieniuch CE and Hubbard E. "From preventative to predictive maintenance: The organisational challenge". *Journal of Rail and Rapid Transit* 2017; 231(10).
3. Bernocchi M and Miguelanez E. "The contribution of European research to more intelligent railway maintenance: the InteGRail project". In: Euromaintenance 2010 International Congress, Verona Fiere, 14th May 2010.
4. Shingler R, Fadin G and Umiliacchi P. "From RCM to predictive maintenance: the InteGRail approach". 4th IET International Conference on Railway Condition Monitoring, Derby, 18th June 2008.
5. He K, Zhang X, Ren S and Sun J. «Delving deep into rectifiers: surpassing human level performance on image net classification». In: ICCV'15 Proceedings of the 2015 IEEE International Conference on Computer Vision (ICCV), Santiago, Chile, 7-13 Dec. 2015, pp. 1026–1034.
6. Glorot Y and Bengio Y. «Understanding difficulty training deep feed forward neural networks». Proc Thirteenth International Conference Artificial Intelligence Statistics, Sardinia, Italy, 13-15 May 2010, 249–256.
7. Kingma DP and Ba J. «Adam: a method for stochastic optimization». In: International Conference on Learning Representations (ICLR), San Diego, 2015.
8. Geman SE, Bienenstock E and Doursat R. «Neural networks and the bias/variance dilemma». *Neural Computations* 1992; 41: 1–58.
9. Foody GM, McCulloch MB and Yates WB. The effect of training set size and composition on artificial neural network classification. *Int J Remote Sensing* 1995; 16(9): 1707–1723. DOI: [10.1080/01431169508954507](https://doi.org/10.1080/01431169508954507).
10. Ruder S. *An overview of gradient descent optimization algorithms*. arXiv preprint arXiv:1609.04747, 2016

Author Biography

Pablo Garrido was born in Madrid in 1992. He is Industrial Engineer (graduate and Master's degree) by the Universidad Politécnica de Madrid. He works in Talgo (spanish rail manufacturer since 2014) where currently is Project Manager of the new High Speed Trains for DB (Germany). He has been the project manager of the High Speed Trains in Spain and the Russian Project. He has a wide experience in the rail sector and participates in many congress, forums, research projects in national or international programs. He is also Adjunct Professor in Applied Mathematics Department - Universidad Politécnica de Madrid, but he also taught in the Mechanical Engineering Department. Currently he is also studying Mathematics in UNED, and his investigation lines are related with applied mathematics, artificial intelligence applied to railway, industry and maintenance 4.0,... On the other hand, since September 2020 he is Board Member of the Cedel Foundation.


Juan de Dios Sanz. Professor in Mechanical Engineering Department-Universidad Politecnica de Madrid. He has participated in more than 50 rail research projects funded by European and Spanish national and regional programs. He is member of the Scientific Committee in Shift2Rail that continues as Europe's Rail JU in Horizon Europe

Alberto Huerta. He is Industrial Engineer (graduate and Master's degree) by the Universidad Politécnica de Madrid and Technical University of Munich. He has also participated in the Leadership International Program in Engineering of the Universidad Politécnica de Madrid in cooperation with the Rafael del Pino Foundation. Since June 2019 he works in McKinsey & Company currently as a Senior Business Analyst.

ANEXO I: Mapas de calor del 80% de los desplazamientos producidos desde cada una de las provincias de España


ÁLAVA:

Origen	Destino	Desplazamientos (%)
Álava	Vizcaya	34,51
Álava	Burgos	19,12
Álava	La Rioja	18,85
Álava	Guipúzcoa	13,11
Álava	Navarra	6,93
Álava	Cantabria	2,08
Álava	Madrid	1,06
Álava	Zaragoza	0,81
Álava	Valladolid	0,37
Álava	Barcelona	0,31




ALBACETE:

Origen	Destino	Desplazamientos (%)
Albacete	Cuenca	26,22
Albacete	Murcia	19,61
Albacete	Alicante	15,56
Albacete	Valencia	12,78
Albacete	Ciudad Real	12,15
Albacete	Madrid	3,57
Albacete	Jaén	2,64
Albacete	Toledo	2,06
Albacete	Castellón	0,7
Albacete	Barcelona	0,51




ALICANTE

Origen	Destino	Desplazamientos (%)
Alicante	Murcia	49,22
Alicante	Valencia	34,32
Alicante	Albacete	5,25
Alicante	Madrid	3,34
Alicante	Castellón	1
Alicante	Almería	0,87
Alicante	Barcelona	0,7
Alicante	Granada	0,56
Alicante	Baleares	0,47
Alicante	Cuenca	0,45




ALMERÍA:

Origen	Destino	Desplazamientos (%)
Almería	Murcia	42,71
Almería	Granada	33,43
Almería	Málaga	4,93
Almería	Jaén	3,21
Almería	Alicante	2,96
Almería	Madrid	2,71
Almería	Valencia	1,91
Almería	Sevilla	1,29
Almería	Barcelona	1,15
Almería	Córdoba	0,76




ÁVILA:

Origen	Destino	Desplazamientos (%)
Ávila	Madrid	37,18
Ávila	Toledo	15,32
Ávila	Salamanca	14,93
Ávila	Segovia	11,02
Ávila	Valladolid	10,39
Ávila	Cáceres	5,79
Ávila	Zamora	0,68
Ávila	León	0,45
Ávila	Palencia	0,35
Ávila	Burgos	0,35




BADAJOS:

Origen	Destino	Desplazamientos (%)
Badajoz	Cáceres	50,94
Badajoz	Sevilla	12,78
Badajoz	Huelva	9,07
Badajoz	Córdoba	6,53
Badajoz	Madrid	6,26
Badajoz	Ciudad Real	3,03
Badajoz	Cádiz	2,04
Badajoz	Toledo	1,92
Badajoz	Salamanca	1,21
Badajoz	Málaga	0,86




BALEARES:

Origen	Destino	Desplazamientos (%)
Baleares	Barcelona	33,46
Baleares	Valencia	18
Baleares	Madrid	16,32
Baleares	Alicante	6,26
Baleares	Sevilla	2,17
Baleares	Málaga	1,72
Baleares	Granada	1,59
Baleares	Vizcaya	1,59
Baleares	Murcia	1,34
Baleares	Girona	1,14




BARCELONA:

Origen	Destino	Desplazamientos (%)
Barcelona	Girona	45,48
Barcelona	Tarragona	29,84
Barcelona	Lérida	9,74
Barcelona	Zaragoza	2,31
Barcelona	Madrid	1,8
Barcelona	Valencia	1,67
Barcelona	Baleares	1,36
Barcelona	Huesca	1,15
Barcelona	Castellón	1,13
Barcelona	Alicante	0,51




BURGOS:

Origen	Destino	Desplazamientos (%)
Burgos	Álava	28,46
Burgos	Vizcaya	12,78
Burgos	Cantabria	9,9
Burgos	Palencia	9,01
Burgos	Valladolid	8,21
Burgos	La Rioja	6,14
Burgos	Madrid	5,56
Burgos	Soria	4,18
Burgos	Segovia	2,45
Burgos	Guipúzcoa	1,9




CÁCERES:

Origen	Destino	Desplazamientos (%)
Cáceres	Badajoz	50,81
Cáceres	Salamanca	13,56
Cáceres	Toledo	11,04
Cáceres	Madrid	9,89
Cáceres	Ávila	4,75
Cáceres	Sevilla	1,88
Cáceres	Cádiz	0,75
Cáceres	Valladolid	0,71
Cáceres	Huelva	0,62
Cáceres	Ciudad Real	0,47




CÁDIZ:

Origen	Destino	Desplazamientos (%)
Cádiz	Sevilla	48,82
Cádiz	Málaga	32,96
Cádiz	Ceuta	3,26
Cádiz	Huelva	2,45
Cádiz	Madrid	2,35
Cádiz	Córdoba	2,02
Cádiz	Granada	1,85
Cádiz	Badajoz	1,14
Cádiz	Jaén	1,03
Cádiz	Cáceres	0,44




CASTELLÓN DE LA PLANA:

Origen	Destino	Desplazamientos (%)
Castellón	Valencia	65,74
Castellón	Tarragona	15,51
Castellón	Teruel	4,47
Castellón	Barcelona	3,24
Castellón	Alicante	2,12
Castellón	Madrid	1,6
Castellón	Zaragoza	1,35
Castellón	Murcia	0,84
Castellón	Cuenca	0,6
Castellón	Albacete	0,59




CIUDAD REAL:

Origen	Destino	Desplazamientos (%)
Ciudad Real	Toledo	30,75
Ciudad Real	Madrid	20,88
Ciudad Real	Albacete	13,65
Ciudad Real	Cuenca	7,54
Ciudad Real	Jaén	4,94
Ciudad Real	Córdoba	4,61
Ciudad Real	Badajoz	2,69
Ciudad Real	Valencia	2,59
Ciudad Real	Sevilla	1,73
Ciudad Real	Málaga	1,29




CÓRDOBA:

Origen	Destino	Desplazamientos (%)
Córdoba	Sevilla	38,69
Córdoba	Jaén	19,24
Córdoba	Málaga	17,37
Córdoba	Granada	8,19
Córdoba	Badajoz	4,07
Córdoba	Ciudad Real	3,19
Córdoba	Cádiz	2,16
Córdoba	Madrid	1,94
Córdoba	Huelva	1,15
Córdoba	Almería	0,54




LA CORUÑA:

Origen	Destino	Desplazamientos (%)
La Coruña	Pontevedra	69,23
La Coruña	Lugo	19,79
La Coruña	Orense	3,62
La Coruña	León	1,58
La Coruña	Madrid	1,45
La Coruña	Asturias	1,36
La Coruña	Zamora	0,35
La Coruña	Barcelona	0,3
La Coruña	Valladolid	0,21
La Coruña	Vizcaya	0,18




CUENCA:

Origen	Destino	Desplazamientos (%)
Cuenca	Albacete	31,97
Cuenca	Madrid	18,7
Cuenca	Valencia	13,33
Cuenca	Toledo	12,69
Cuenca	Ciudad Real	8,26
Cuenca	Guadalajara	6,44
Cuenca	Alicante	1,46
Cuenca	Murcia	1,42
Cuenca	Castellón	0,89
Cuenca	Teruel	0,59



GIRONA:

Origen	Destino	Desplazamientos (%)
Girona	Barcelona	91,64
Girona	Lérida	4,05
Girona	Tarragona	1,41
Girona	Valencia	0,47
Girona	Zaragoza	0,4
Girona	Castellón	0,33
Girona	Madrid	0,3
Girona	Huesca	0,26
Girona	Murcia	0,16
Girona	Alicante	0,16




GRANADA:

Origen	Destino	Desplazamientos (%)
Granada	Málaga	26,45
Granada	Almería	23,9
Granada	Jaén	22,1
Granada	Córdoba	8,69
Granada	Murcia	4,26
Granada	Sevilla	3,52
Granada	Madrid	2,31
Granada	Cádiz	2
Granada	Alicante	1,42
Granada	Ciudad Real	0,75




GUADALAJARA:

Origen	Destino	Desplazamientos (%)
Guadalajara	Madrid	86,15
Guadalajara	Cuenca	3,14
Guadalajara	Toledo	1,84
Guadalajara	Zaragoza	1,25
Guadalajara	Valencia	0,63
Guadalajara	Soria	0,59
Guadalajara	Barcelona	0,55
Guadalajara	Teruel	0,53
Guadalajara	Ciudad Real	0,53
Guadalajara	Segovia	0,51




GUIPUZCUA:

Origen	Destino	Desplazamientos (%)
Guipúzcoa	Vizcaya	47,46
Guipúzcoa	Navarra	21,09
Guipúzcoa	Álava	17,03
Guipúzcoa	Cantabria	2,13
Guipúzcoa	La Rioja	1,91
Guipúzcoa	Burgos	1,81
Guipúzcoa	Madrid	1,72
Guipúzcoa	Zaragoza	1,27
Guipúzcoa	Barcelona	0,68
Guipúzcoa	Huesca	0,5




HUELVA:

Origen	Destino	Desplazamientos (%)
Huelva	Sevilla	74,88
Huelva	Badajoz	10
Huelva	Cádiz	4,39
Huelva	Córdoba	2,18
Huelva	Madrid	1,46
Huelva	Málaga	1,43
Huelva	Cáceres	1
Huelva	Jaén	0,81
Huelva	Granada	0,8
Huelva	Ciudad Real	0,32




HUESCA:

Origen	Destino	Desplazamientos (%)
Huesca	Zaragoza	39,79
Huesca	Lérida	39,4
Huesca	Barcelona	6,99
Huesca	Tarragona	2,79
Huesca	Navarra	2,66
Huesca	Madrid	1,22
Huesca	Teruel	1,07
Huesca	Girona	0,86
Huesca	Guipúzcoa	0,83
Huesca	Valencia	0,7




JAÉN:

Origen	Destino	Desplazamientos (%)
Jaén	Granada	31,7
Jaén	Córdoba	29,59
Jaén	Málaga	6,3
Jaén	Ciudad Real	5,15
Jaén	Madrid	5,11
Jaén	Sevilla	4,9
Jaén	Almería	3,29
Jaén	Albacete	3,23
Jaén	Cádiz	1,63
Jaén	Murcia	1,25




LEÓN:

Origen	Destino	Desplazamientos (%)
León	Zamora	18,31
León	Asturias	18,18
León	Orense	12,37
León	Valladolid	11,52
León	Palencia	7,23
León	Madrid	6,33
León	Lugo	5,17
León	La Coruña	4,44
León	Burgos	2,44
León	Salamanca	2,06




LLEIDA:

Origen	Destino	Desplazamientos (%)
Lleida	Barcelona	39,83
Lleida	Huesca	27,56
Lleida	Tarragona	15,7
Lleida	Girona	7,95
Lleida	Zaragoza	4,12
Lleida	Madrid	0,72
Lleida	Valencia	0,72
Lleida	Castellón	0,58
Lleida	Navarra	0,39
Lleida	Teruel	0,38




LA RIOJA:

Origen	Destino	Desplazamientos (%)
La Rioja	Navarra	54,47
La Rioja	Álava	23,25
La Rioja	Burgos	5,14
La Rioja	Zaragoza	3,33
La Rioja	Vizcaya	3,25
La Rioja	Guipúzcoa	1,87
La Rioja	Madrid	1,43
La Rioja	Soria	1,34
La Rioja	Cantabria	1,03
La Rioja	Barcelona	0,7




LUGO:

Origen	Destino	Desplazamientos (%)
Lugo	La Coruña	40,97
Lugo	Asturias	23,99
Lugo	Orense	17,81
Lugo	Pontevedra	9,54
Lugo	León	3,72
Lugo	Madrid	1,08
Lugo	Zamora	0,35
Lugo	Valladolid	0,34
Lugo	Cantabria	0,33
Lugo	Vizcaya	0,21




MADRID:

Origen	Destino	Desplazamientos (%)
Madrid	Toledo	41,76
Madrid	Guadalajara	22,99
Madrid	Ávila	3,89
Madrid	Segovia	3,5
Madrid	Ciudad Real	2,98
Madrid	Cuenca	2,29
Madrid	Valencia	1,75
Madrid	Alicante	1,41
Madrid	Cáceres	1,19
Madrid	Barcelona	1,15




MÁLAGA:

Origen	Destino	Desplazamientos (%)
Málaga	Cádiz	30,54
Málaga	Granada	21,46
Málaga	Sevilla	15,82
Málaga	Córdoba	15,25
Málaga	Madrid	3,46
Málaga	Jaén	3,4
Málaga	Almería	3,09
Málaga	Murcia	0,74
Málaga	Huelva	0,73
Málaga	Ciudad Real	0,61




MURCIA:

Origen	Destino	Desplazamientos (%)
Murcia	Alicante	60,72
Murcia	Almería	15,16
Murcia	Albacete	8,31
Murcia	Valencia	4,28
Murcia	Madrid	2,38
Murcia	Granada	2,13
Murcia	Barcelona	0,72
Murcia	Castellón	0,57
Murcia	Málaga	0,54
Murcia	Jaén	0,48




NAVARRA:

Origen	Destino	Desplazamientos (%)
Navarra	La Rioja	44,34
Navarra	Zaragoza	17,65
Navarra	Guipúzcoa	15,97
Navarra	Álava	6,72
Navarra	Vizcaya	2,98
Navarra	Madrid	1,93
Navarra	Huesca	1,31
Navarra	Soria	1,13
Navarra	Barcelona	1,01
Navarra	Burgos	0,93




OURENSE:

Origen	Destino	Desplazamientos (%)
Ourense	Pontevedra	45,05
Ourense	Lugo	24,05
Ourense	León	11,53
Ourense	La Coruña	10,09
Ourense	Zamora	3,38
Ourense	Madrid	1,87
Ourense	Valladolid	0,56
Ourense	Asturias	0,47
Ourense	Barcelona	0,26
Ourense	Salamanca	0,23




ASTURIAS:

Origen	Destino	Desplazamientos (%)
Asturias	Lugo	33,53
Asturias	Cantabria	20,45
Asturias	León	17,93
Asturias	Madrid	6
Asturias	La Coruña	3,69
Asturias	Vizcaya	2,77
Asturias	Valladolid	1,71
Asturias	Pontevedra	1,43
Asturias	Zamora	1,38
Asturias	Burgos	1,08




PALENCIA:

Origen	Destino	Desplazamientos (%)
Palencia	Valladolid	43,75
Palencia	Burgos	16,82
Palencia	Cantabria	14,49
Palencia	León	9,17
Palencia	Madrid	3
Palencia	Zamora	1,72
Palencia	Vizcaya	1,52
Palencia	Salamanca	1,23
Palencia	Asturias	1,07
Palencia	Álava	0,82




LAS PALMAS:

Origen	Destino	Desplazamientos (%)
Las Palmas	Santacruz	62,05
Las Palmas	Madrid	13,78
Las Palmas	Barcelona	5,24
Las Palmas	Sevilla	1,87
Las Palmas	La Coruña	1,36
Las Palmas	Málaga	1,28
Las Palmas	Vizcaya	1,1
Las Palmas	Valencia	1,09
Las Palmas	Pontevedra	1,02
Las Palmas	Baleares	0,94




PONTEVEDRA:

Origen	Destino	Desplazamientos (%)
Pontevedra	La Coruña	72,81
Pontevedra	Orense	17,2
Pontevedra	Lugo	4,91
Pontevedra	Madrid	1,26
Pontevedra	Zamora	0,66
Pontevedra	León	0,63
Pontevedra	Asturias	0,55
Pontevedra	Valladolid	0,25
Pontevedra	Barcelona	0,15
Pontevedra	Burgos	0,12




SALAMANCA:

Origen	Destino	Desplazamientos (%)
Salamanca	Zamora	22,63
Salamanca	Cáceres	19,39
Salamanca	Ávila	17,68
Salamanca	Valladolid	13,08
Salamanca	Madrid	8,84
Salamanca	León	2,37
Salamanca	Badajoz	1,89
Salamanca	Segovia	1,43
Salamanca	Burgos	1,36
Salamanca	Palencia	1,19




SANTA CRUZ:

Origen	Destino	Desplazamientos (%)
Santa Cruz	Las Palmas	68,2
Santa Cruz	Madrid	11,93
Santa Cruz	Barcelona	3,88
Santa Cruz	Sevilla	1,46
Santa Cruz	La Coruña	1,18
Santa Cruz	Málaga	1,04
Santa Cruz	Valencia	0,98
Santa Cruz	Pontevedra	0,81
Santa Cruz	Baleares	0,75
Santa Cruz	Alicante	0,75




CANTABRIA:

Origen	Destino	Desplazamientos (%)
Cantabria	Vizcaya	51,26
Cantabria	Asturias	13,28
Cantabria	Burgos	9,24
Cantabria	Palencia	7,34
Cantabria	Madrid	3,57
Cantabria	Álava	2,83
Cantabria	Guipúzcoa	2,26
Cantabria	Valladolid	1,91
Cantabria	La Rioja	1,21
Cantabria	Navarra	0,98




SEGOVIA:

Origen	Destino	Desplazamientos (%)
Segovia	Madrid	40,05
Segovia	Valladolid	28,93
Segovia	Ávila	13,39
Segovia	Burgos	4,41
Segovia	Guadalajara	1,55
Segovia	Salamanca	1,39
Segovia	Soria	1,37
Segovia	Toledo	1,23
Segovia	Palencia	0,76
Segovia	Zamora	0,65




SEVILLA:

Origen	Destino	Desplazamientos (%)
Sevilla	Cádiz	28,99
Sevilla	Huelva	23,98
Sevilla	Córdoba	21,72
Sevilla	Málaga	10,25
Sevilla	Badajoz	4,17
Sevilla	Granada	2
Sevilla	Jaén	1,76
Sevilla	Madrid	1,7
Sevilla	Cáceres	0,62
Sevilla	Ciudad Real	0,6




SORIA:

Origen	Destino	Desplazamientos (%)
Soria	Zaragoza	25,49
Soria	Burgos	19,48
Soria	Madrid	11,13
Soria	Navarra	7,7
Soria	La Rioja	7,31
Soria	Guadalajara	4,92
Soria	Valladolid	3,56
Soria	Segovia	3,42
Soria	Barcelona	2,33
Soria	Valencia	1




TARRAGONA:

Origen	Destino	Desplazamientos (%)
Tarragona	Barcelona	67
Tarragona	Castellón	11,7
Tarragona	Lérida	8,61
Tarragona	Zaragoza	2,49
Tarragona	Valencia	2,34
Tarragona	Teruel	1,73
Tarragona	Girona	1,58
Tarragona	Huesca	1,11
Tarragona	Madrid	0,54
Tarragona	Alicante	0,44




TERUEL:

Origen	Destino	Desplazamientos (%)
Teruel	Zaragoza	43,84
Teruel	Castellón	15,68
Teruel	Valencia	15,62
Teruel	Tarragona	7,87
Teruel	Barcelona	2,7
Teruel	Guadalajara	2,1
Teruel	Huesca	1,82
Teruel	Navarra	1,36
Teruel	Cuenca	1,28
Teruel	Alicante	1,17




TOLEDO:

Origen	Destino	Desplazamientos (%)
Toledo	Madrid	76,84
Toledo	Ciudad Real	8,06
Toledo	Cuenca	3,06
Toledo	Ávila	2,96
Toledo	Cáceres	2,64
Toledo	Guadalajara	0,9
Toledo	Albacete	0,65
Toledo	Valencia	0,55
Toledo	Badajoz	0,49
Toledo	Alicante	0,33




VALENCIA:

Origen	Destino	Desplazamientos (%)
Valencia	Alicante	35,82
Valencia	Castellón	32,49
Valencia	Albacete	4,59
Valencia	Cuenca	4,15
Valencia	Madrid	3,97
Valencia	Murcia	3,73
Valencia	Barcelona	2,28
Valencia	Teruel	2,14
Valencia	Tarragona	1,45
Valencia	Zaragoza	1,26




VALLADOLID:

Origen	Destino	Desplazamientos (%)
Valladolid	Palencia	22,51
Valladolid	Segovia	15,44
Valladolid	Zamora	14,57
Valladolid	Burgos	7,67
Valladolid	León	7,34
Valladolid	Salamanca	7,05
Valladolid	Madrid	6,77
Valladolid	Ávila	6,7
Valladolid	Cantabria	1,81
Valladolid	Asturias	1,1




VIZCAYA:

Origen	Destino	Desplazamientos (%)
Vizcaya	Cantabria	28,03
Vizcaya	Guipúzcoa	27,65
Vizcaya	Álava	26,24
Vizcaya	Burgos	6,52
Vizcaya	Navarra	2,24
Vizcaya	La Rioja	1,92
Vizcaya	Madrid	1,43
Vizcaya	Asturias	0,85
Vizcaya	Zaragoza	0,7
Vizcaya	Barcelona	0,46




ZAMORA:

Origen	Destino	Desplazamientos (%)
Zamora	Valladolid	26,77
Zamora	Salamanca	22,56
Zamora	León	22,28
Zamora	Madrid	5,92
Zamora	Orense	4,75
Zamora	Pontevedra	2,38
Zamora	Asturias	2,27
Zamora	La Coruña	2,09
Zamora	Palencia	1,6
Zamora	Burgos	1,03



ZARAGOZA:

Origen	Destino	Desplazamientos (%)
Zaragoza	Huesca	22,62
Zaragoza	Navarra	20,47
Zaragoza	Teruel	14,16
Zaragoza	Barcelona	6,45
Zaragoza	Madrid	6,16
Zaragoza	Soria	4,25
Zaragoza	Lérida	3,38
Zaragoza	Tarragona	3,28
Zaragoza	La Rioja	3,16
Zaragoza	Valencia	2,77



CEUTA:

Origen	Destino	Desplazamientos (%)
Ceuta	Cádiz	82,03
Ceuta	Málaga	10,34
Ceuta	Sevilla	2,94
Ceuta	Granada	1,18
Ceuta	Córdoba	0,61
Ceuta	Madrid	0,53
Ceuta	Huelva	0,38
Ceuta	Jaén	0,37
Ceuta	Almería	0,31
Ceuta	Badajoz	0,22

MELILLA:

Origen	Destino	Desplazamientos (%)
Melilla	Málaga	51,5
Melilla	Almería	15,81
Melilla	Granada	9,75
Melilla	Madrid	6,48
Melilla	Sevilla	4,23
Melilla	Cádiz	1,88
Melilla	Murcia	1,68
Melilla	Córdoba	1,03
Melilla	Jaén	0,93
Melilla	Alicante	0,87

ANEXO II: Medio de transporte más rápido y más económico en cada uno de los trayectos posibles entre las distintas provincias de España

		porcentajes	mas rapido	tiempo (h)	mas barato	precio (€)	AVE
Albacete	Cuenca	26,22	tren	0,6	coche	14,6	SI
Albacete	Murcia	19,61	coche	1,45	coche	12,9	SI
Albacete	Alicante	15,56	tren	0,9	tren	12	SI
Albacete	Valencia	12,78	tren	1,55	coche	19	SI
Albacete	Ciudad Real	12,15	coche	2,1	coche	17,9	SI

		porcentajes	más rápido	tiempo (h)	más económico	precio (€)	AVE
Alicante	Murcia	49,22	coche	0,85	autobus	7	SI
Alicante	Valencia	34,32	tren	1,79	tren	13	NO

		porcentajes	mas rapido	tiempo (h)	mas barato	precio (€)	AVE
Ávila	Madrid	37,18	coche	1,35	tren	9	NO
Ávila	Toledo	15,32	coche	1,666	tren	6,3	NO
Ávila	Salamanca	14,93	coche	1,1	coche	9,8	NO
Ávila	Segovia	11,02	coche	0,9	coche	6,4	NO

		porcentajes	mas rapido	tiempo (h)	mas barato	precio (€)	AVE
Badajoz	Cáceres	50,94	coche	1,2	tren	8	NO
Badajoz	Sevilla	12,78	coche	2,45	autobus	15	NO
Badajoz	Huelva	9,07	coche	3	coche	21	NO
Badajoz	Córdoba	6,53	coche	3,2	coche	23,7	NO
Badajoz	Madrid	6,26	coche	3,933	autobus	33	NO

		porcentaje	más rápido	tiempo (h)	más económico	precio (€)	AVE
Barcelona	Gerona	45,48	tren	0,6	coche	9,1	SI
Barcelona	Tarragona	28,94	tren	1,133	tren	10	SI
Barcelona	Lérida	9,74	tren	1	coche	14,2	SI

		porcentajes	más rápido	tiempo (h)	más económico	precio (€)	AVE
Bilbao	Santander	28,03	coche	1,15	autobus	7	NO
Bilbao	San Sebastián	27,65	autobus	1,33	autobus	7	NO
Bilbao	Vitoria	26,24	coche	0,9	coche	7,3	NO

		porcentajes	mas rapido	tiempo (h)	mas barato	precio (€)	AVE
Burgos	Vitoria	28,46	coche	1,2	coche	10,9	NO
Burgos	Bilbao	12,78	coche	1,6	autobus	14	NO
Burgos	Santander	9,9	coche	1,85	autobus	13	NO
Burgos	Palencia	9,01	tren	0,8	tren	8	SI
Burgos	Valladolid	8,21	tren	0,8	coche	11,6	SI
Burgos	Logroño	6,14	coche	1,5	autobus	8	NO
Burgos	Madrid	5,56	tren	2,433	autobus	13	SI

		porcentajes	mas rapido	tiempo (h)	mas barato	precio (€)	AVE
Cáceres	Badajoz	50,81	coche	1,2	coche	8,3	NO
Cáceres	Salamanca	13,56	coche	0,75	autobus	17	NO
Cáceres	Toledo	11,04	coche	2,4	coche	23,3	NO
Cáceres	Madrid	9,89	coche	3	tren	14,3	NO

		porcentajes	mas rapido	tiempo (h)	mas barato	precio (€)	AVE
Cádiz	Sevilla	48,82	coche	1,2	tren	8	SI
Cádiz	Málaga	32,96	coche	2,9	coche	21,2	NO

		porcentajes	mas rapido	tiempo (h)	mas barato	precio (€)	AVE
Castellón	Valencia	65,74	tren	0,75	tren	6	SI
Castellón	Tarragona	15,51	tren	1,9	tren	13	NO

		porcentajes	mas rapido	tiempo (h)	mas barato	precio (€)	AVE
Ciudad Real	Toledo	30,75	coche	1,4	coche	10,5	SI
Ciudad Real	Madrid	20,88	tren	0,9	tren	16	SI
Ciudad Real	Albacete	13,65	coche	2,1	coche	17,9	SI
Ciudad Real	Cuenca	7,54	coche	2,666	coche	23,5	SI
Ciudad Real	Jaén	4,94	coche	1,9	coche	15,5	NO
Ciudad Real	Córdoba	4,61	tren	1	coche	17,5	SI

		porcentajes	más rápido	tiempo (h)	más económico	precio (€)	AVE
Córdoba	Sevilla	38,69	tren	0,7	coche	12,6	SI
Córdoba	Jaén	19,24	coche	1,4	coche	10,1	NO
Córdoba	Málaga	17,37	tren	1,2	coche	14,2	SI
Córdoba	Granada	8,19	tren	1,35	coche	18,6	SI

		porcentajes	mas rapido	tiempo (h)	mas barato	precio (€)	AVE
Cuenca	Albacete	31,97	tren	0,6	coche	14,6	SI
Cuenca	Madrid	18,7	tren	0,833	tren	14	SI
Cuenca	Valencia	13,33	tren	0,9	tren	8	SI
Cuenca	Toledo	12,69	coche	2,1	tren	19	SI
Cuenca	Ciudad Real	8,26	coche	2,666	coche	23,5	SI

		porcentajes	mas rapido	tiempo (h)	mas barato	precio (€)	AVE
Gerona	Barcelona	91,64	tren	0,6	coche	9,1	SI

		porcentajes	más rápida	tiempo (h)	más económico	precio (€)	AVE
Granada	Málaga	26,45	tren	1,2	coche	11,3	SI
Granada	Almería	23,9	coche	1,666	coche	14,9	NO
Granada	Jaén	22,1	coche	1	coche	8,4	NO
Granada	Córdoba	8,69	tren	1,35	coche	18,6	SI

		porcentajes	mas rapido	tiempo (h)	mas barato	precio (€)	AVE
Guadalajara	Madrid	86,15	coche	0,9	coche	6	SI

		porcentajes	mas rapido	tiempo (h)	mas barato	precio (€)	AVE
Huelva	Sevilla	74,88	coche	1	coche	8,3	NO
Huelva	Badajoz	10	coche	3	coche	21	NO

		porcentajes	mas rapido	tiempo (h)	mas barato	precio (€)	AVE
Huesca	Zaragoza	39,79	tren	0,75	tren	5	SI
Huesca	Lérida	39,4	coche	1,4	coche	10	SI
Huesca	Barcelona	6,99	coche	2,9	autobus	13	SI

		porcentajes	mas rapido	tiempo (h)	mas barato	precio (€)	AVE
Jaén	Granada	31,7	coche	1	coche	8,4	NO
Jaén	Córdoba	29,59	coche	1,4	coche	10,1	NO
Jaén	Málaga	6,3	coche	2,25	coche	17	NO
Jaén	Ciudad Real	5,15	coche	1,9	coche	15,5	NO
Jaén	Madrid	5,11	coche	3,416	autobus	17	NO
Jaén	Sevilla	4,9	coche	2,6	coche	22	NO

		porcentajes	más rápido	tiempo (h)	económico	precio (€)	AVE
La Coruña	Pontevedra	69,23	tren	1,133	tren	10	SI
La Coruña	Lugo	19,79	coche	1,1	coche	8,5	SI

		porcentajes	mas rapido	tiempo (h)	mas barato	precio (€)	AVE
León	Zamora	18,31	coche	1,5	coche	13,2	SI
León	Oviedo	18,18	coche	1,6	tren	7	NO
León	Orense	12,37	coche	2,75	coche	26,7	SI
León	Valladolid	11,52	tren	1,133	autobus	12	SI
León	Palencia	7,23	tren	0,75	coche	10,9	SI
León	Madrid	6,33	tren	2	autobus	17	SI
León	Lugo	5,17	coche	2,3	tren	19	NO
León	La Coruña	4,44	coche	3,9	tren	26	SI

		porcentajes	mas rapido	tiempo (h)	mas barato	precio (€)	AVE
Lérida	Barcelona	39,83	tren	1	coche	14,2	SI
Lérida	Huesca	27,56	coche	1,4	coche	10	SI
Lérida	Tarragona	15,7	coche	1,2	tren	7	SI

		porcentajes	mas rapido	tiempo (h)	mas barato	precio (€)	AVE
Logroño	Pamplona	54,47	coche	0,95	coche	7,6	NO
Logroño	Vitoria	23,25	coche	1,1	coche	5,9	NO
Logroño	Burgos	5,14	coche	1,5	autobus	8	NO

		porcentajes	mas rapido	tiempo (h)	mas barato	precio (€)	AVE
Lugo	La Coruña	40,97	coche	1,1	coche	8,5	NO
Lugo	Oviedo	23,99	coche	2,5	coche	22,1	NO
Lugo	Orense	17,81	coche	1,33	coche	8,3	NO

		porcentajes	más rápido	tiempo (h)	más económico	precio (€)	AVE
Madrid	Toledo	41,76	tren	0,54	coche	6,5	SI
Madrid	Guadalajara	22,99	coche	0,9	coche	6	SI
Madrid	Ávila	3,89	coche	1,35	tren	9	NO
Madrid	Segovia	3,5	tren	0,45	coche	8,2	SI
Madrid	Ciudad Real	2,98	tren	0,9	tren	16	SI
Madrid	Cuenca	2,29	tren	0,833	tren	14	SI
Madrid	Valencia	1,75	avión	1	tren	19	SI
Madrid	Alicante	1,41	avión	1	tren	21	SI

		porcentaje	más rápido	tiempo (h)	más económico	precio (€)	AVE
Málaga	Cádiz	30,54	coche	2,9	coche	21,2	SI
Málaga	Granada	21,46	tren	1,2	coche	11,3	SI
Málaga	Sevilla	15,82	tren	2	coche	18,4	SI
Málaga	Córdoba	15,25	tren	1,2	coche	14,2	SI

		porcentaje	más rápido	tiempo (h)	más económico	precio (€)	AVE
Murcia	Alicante	60,72	coche	0,85	autobus	7	SI
Murcia	Almería	15,16	coche	2,1	autobus	14	NO
Murcia	Albacete	8,31	coche	1,45	coche	12,9	SI

		porcentajes	mas rapido	tiempo (h)	mas barato	precio (€)	AVE
Orense	Pontevedra	45,05	coche	1,3	coche	10,5	NO
Orense	Lugo	24,05	coche	1,33	coche	8,3	NO
Orense	León	11,53	coche	2,75	coche	26,7	SI

		porcentajes	más rápido	tiempo (h)	más económico	precio (€)	AVE
Oviedo	Lugo	33,53	coche	2,5	coche	22,1	NO
Oviedo	Santander	20,45	coche	1,9	autobus	16	NO
Oviedo	León	17,93	coche	1,6	tren	7	NO
Oviedo	Madrid	6	avión	1,166	tren	34	NO
Oviedo	La Coruña	3,69	coche	2,8	autobus	25	NO

		porcentajes	mas rapido	tiempo (h)	mas barato	precio (€)	AVE
Palencia	Valladolid	43,75	tren	0,4	autobus	3	SI
Palencia	Burgos	16,82	tren	0,8	tren	8	SI
Palencia	Santander	14,49	coche	1,9	tren	8	NO
Palencia	León	9,17	tren	0,75	coche	10,9	SI

		porcentajes	más rápido	tiempo (h)	más económico	precio (€)	AVE
Pamplona	Logroño	44,34	coche	0,95	coche	7,6	NO
Pamplona	Zaragoza	17,65	tren	1,9	tren	13	NO
Pamplona	San Sebastián	15,97	coche	1,1	coche	7,4	NO
Pamplona	Vitória	6,72	coche	1,05	tren	6	NO

		porcentajes	mas rapido	tiempo (h)	mas barato	precio (€)	AVE
Pontevedra	La Coruña	72,81	tren	1,133	tren	10	NO
Pontevedra	Orense	17,2	coche	1,3	coche	10,5	NO

		porcentajes	mas rapido	tiempo (h)	mas barato	precio (€)	AVE
Salamanca	Zamora	22,63	coche	0,75	coche	5,8	NO
Salamanca	Cáceres	19,39	coche	1,9	autobus	17	NO
Salamanca	Ávila	17,68	coche	1,1	coche	9,8	NO
Salamanca	Valladolid	13,08	coche	1,4	coche	10,9	NO
Salamanca	Madrid	8,84	tren	1,683	tren	13	NO

		porcentajes	más rápido	tiempo (h)	más barato	precio (€)	AVE
San Sebastián	Bilbao	47,46	autobus	1,33	autobus	7	NO
San Sebastián	Pamplona	21,09	coche	1,1	coche	7,4	NO
San Sebastián	Vitória	17,03	coche	1.25	autobus	7	NO

		porcentajes	mas rapido	tiempo (h)	mas barato	precio (€)	AVE
Santander	Bilbao	51,26	coche	1,15	autobus	7	NO
Santander	Oviedo	13,28	coche	1,9	autobus	16	NO
Santander	Burgos	9,24	coche	1,85	autobus	13	NO
Santander	Palencia	7,34	coche	1,9	tren	8	NO

		porcentajes	mas rapido	tiempo (h)	mas barato	precio (€)	AVE
Segovia	Madrid	40,05	tren	0,45	coche	8,2	SI
Segovia	Valladolid	28,93	tren	1,2	coche	10,5	SI
Segovia	Ávila	13,39	coche	0,9	coche	6,4	NO

		porcentaje	más rápido	tiempo (h)	más económico	precio (€)	AVE
Sevilla	Cádiz	28,99	coche	1,2	tren	8	NO
Sevilla	Huelva	23,98	coche	1	coche	8,3	NO
Sevilla	Córdoba	21,72	tren	0,7	coche	12,6	SI
Sevilla	Málaga	10,25	tren	2	coche	18,4	SI

		porcentajes	mas rapido	tiempo (h)	mas barato	precio (€)	AVE
Soria	Zaragoza	25,49	coche	2,1	coche	16,7	NO
Soria	Burgos	19,48	coche	1,75	coche	12,7	NO
Soria	Madrid	11,13	coche	2,33	tren	17	NO
Soria	Pamplona	7,7	coche	2,1	coche	16	NO
Soria	Logroño	7,31	coche	1,4	coche	9	NO
Soria	Guadalajara	4,92	coche	1,5	coche	15,4	NO
Soria	Valladolid	3,56	coche	2,75	coche	19,3	NO
Soria	Segovia	3,42	coche	2,45	coche	17,7	NO

		porcentajes	mas rapido	tiempo (h)	mas barato	precio (€)	AVE
Tarragona	Barcelona	67	tren	1,133	tren	10	SI
Tarragona	Castellón	11,7	tren	1,9	tren	13	NO
Tarragona	Lérida	8,61	coche	1,2	tren	7	SI

		porcentajes	mas rapido	tiempo (h)	mas barato	precio (€)	AVE
Teruel	Zaragoza	43,84	coche	1,75	tren	15	NO
Teruel	Castellón	15,68	coche	1,6	coche	12,9	NO
Teruel	Valencia	15,62	coche	1,55	coche	12,9	NO
Teruel	Tarragona	7,87	coche	3,5	coche	25,3	NO

		porcentajes	mas rapido	tiempo (h)	mas barato	precio (€)	AVE
Toledo	Madrid	76,84	tren	0,54	coche	6,5	SI
Toledo	Ciudad Real	8,06	coche	1,4	coche	10,5	SI

		porcentaje	más rápido	tiempo (h)	más económico	precio (€)	AVE
Valencia	Alicante	35,82	tren	1,79	tren	13	NO
Valencia	Castellón	32,49	tren	0,75	tren	6	SI
Valencia	Albacete	4,59	tren	1,55	coche	19	NO
Valencia	Cuenca	4,15	tren	0,9	tren	8	SI
Valencia	Madrid	3,97	avión	1	tren	19	SI

		porcentajes	más rápido	tiempo (h)	más económico	precio (€)	AVE
Valladolid	Palencia	22,51	tren	0,4	autobus	3	SI
Valladolid	Segovia	15,44	tren	1,2	coche	10,5	SI
Valladolid	Zamora	14,57	coche	1,2	coche	9,1	SI
Valladolid	Burgos	7,67	tren	0,8	coche	11,6	SI
Valladolid	León	7,34	tren	1,133	autobus	12	SI
Valladolid	Salamanca	7,05	coche	1,4	coche	10,9	NO
Valladolid	Madrid	6,77	tren	1	autobus	9,6	SI

		porcentajes	más rápido	tiempo (h)	más económico	precio (€)	AVE
Vitoria	Bilbao	34,51	coche	0,9	coche	7,3	NO
Vitoria	Burgos	19,12	coche/tren	1,2	coche	10,9	NO
Vitoria	Logroño	18,85	coche	1,1	coche	5,9	NO
Vitoria	San Sebastián	13,11	coche	1,25	autobus	7	NO

		porcentajes	mas rapido	tiempo (h)	mas barato	precio (€)	AVE
Zamora	Valladolid	26,77	coche	1,2	coche	9,1	SI
Zamora	Salamanca	22,56	coche	0,75	coche	5,8	NO
Zamora	León	22,28	coche	1,5	coche	13,2	SI
Zamora	Madrid	5,92	tren	1,2	coche	22,7	SI
Zamora	Orense	4,75	tren	1,1	tren	17	SI

		porcentaje	más rápido	tiempo (h)	más económico	precio (€)	AVE
Zaragoza	Huesca	22,62	tren	0,75	tren	5	SI
Zaragoza	Pamplona	20,47	tren	1,9	tren	13	NO
Zaragoza	Teruel	14,16	coche	1,75	tren	15	NO
Zaragoza	Barcelona	6,45	tren	1,833	tren	13	SI
Zaragoza	Madrid	6,16	tren	1,35	tren	12	SI
Zaragoza	Soria	4,25	coche	2,1	coche	16,7	NO
Zaragoza	Lérida	3,38	tren	0,7	tren	8	SI
Zaragoza	Tarragona	3,28	tren	1,2	tren	11	SI