

Trabajo Fin de Grado

GRADO EN INGENIERÍA EN TECNOLOGÍAS INDUSTRIALES

**ESTIMACIÓN DE LA POTENCIA DISPONIBLE DE UNA PLANTA
FOTOVOLTAICA EN TIEMPO REAL**

MEMORIA

Autor: Yago Ramos Marquès
Director: Eduard Bullich Massagué
Convocatoria: Enero 2022



Escola Tècnica Superior
d'Enginyeria Industrial de Barcelona



Agradecimientos

Quisiera agradecer a mi familia, amigos y pareja por el apoyo y la ayuda brindados durante el desarrollo del TFG.

Especial agradecimiento a mi tutor Eduard Bullich, quien me ha guiado y ayudado durante todo el proceso, además de haberme proporcionado los datos y conocimientos necesarios para poder comprender y realizar el presente trabajo.

Resumen

Una de las principales problemáticas de la energía solar es su dependencia de la meteorología, la cual provoca intermitencias dando lugar a periodos de máxima producción y otros de escasa o nula producción. En el caso de las plantas fotovoltaicas destinadas a la inyección de potencia a la red, para que dichas intermitencias no afecten a la estabilidad de la red se exige el cumplimiento de una serie de normas llamadas *grid codes*. En el presente trabajo se analizará en profundidad la regulación de frecuencia para el cumplimiento de dichos códigos. Concretamente, se centra en la capacidad de inyección de reservas de potencia para cuando se opere en *under frequency*. En este caso la opción más común es inyectar potencia acumulada en ESS. Esta opción puede llegar a ser muy costosa por lo que se analizan alternativas evaluando su precisión sin contemplar comparativas económicas. Más concretamente, se analiza la opción de operar por debajo de las capacidades de la planta fotovoltaica para que, en caso de que se requiera inyectar potencia, se pueda inyectar mediante el aumento de la producción hasta su punto de máxima capacidad. Esta alternativa también tiene una problemática, la dificultad de conocer la potencia disponible de la planta si no se trabaja a capacidad máxima. Para solventar esta problemática se valora destinar un número concreto de inversores a trabajar a máxima capacidad y desarrollar una red neuronal mediante *Deep Learning* que, a partir de la información de estos pocos inversores, pueda estimar la potencia disponible global de la planta. Posteriormente se analizan los resultados obtenidos y se compara el método con otro método ya existente desarrollado por el NREL.

Abstract

One of the main problems of solar energy is its dependence on the weather, which causes intermittency, giving rise to periods of maximum production and others of little or no production. In the case of photovoltaic plants intended for power injection into the grid, so that such intermitencies do not affect the stability of the grid, compliance with a series of rules called grid codes is required. This thesis will analyze in depth the frequency regulation for compliance with these codes. Specifically, it focuses on the ability to inject power reserves for underfrequency operation. In this case the most common option is to inject stored power in ESS. This option can be very costly, so alternatives are analyzed by evaluating their accuracy without considering economic comparisons. More specifically, the option of operating below the capacities of the photovoltaic plant is analyzed so that, in case it is required to inject power, it can be injected by increasing the production up to its maximum power point. This alternative also has a problem, the difficulty of knowing the available power of the plant if it is not working at maximum capacity. To solve this problem, a specific number of inverters are assigned to work at maximum capacity and a neural network is developed using Deep Learning that, based on the information from these few inverters, can estimate the overall available power of the plant. Subsequently, the results obtained are analyzed and the method is compared with another existing method developed by NREL.

Contenido

GLOSARIO	1
1. INTRODUCCIÓN	3
1.1. Objetivos generales.....	3
1.2. Objetivos específicos.....	3
2. ESTADO DEL ARTE	4
2.1. Contexto	4
2.2. Descripción de una planta fotovoltaica.....	5
2.2.1. Elementos de las instalaciones	5
2.2.1.1. Interconexiones de PV modules	5
2.2.1.2. Convertidores	6
2.2.1.3. Transformadores	7
2.2.1.4. Controlador de la planta (PPC)	9
2.2.1.4.1. Arquitectura de control centralizada	9
2.2.1.4.2. Arquitectura de control distribuida	9
2.3. Grid Codes	10
2.4. Métodos de estimación de potencia.....	14
2.4.1. Estimación mediante análisis meteorológico.....	14
2.4.2. Estimación mediante inversores dedicados	15
2.4.3. Método NREL: Highly Accurate Method for Real-Time Active Power Reserve Estimation for Utility-Scale Photovoltaic Power plants	15
2.4.4. Método de aplicación de redes neuronales.....	16
2.5. Inteligencia artificial y <i>Big Data</i>	16
2.5.1. Big Data	16
2.5.2. Inteligencia artificial	17
2.5.3. <i>Machine learning</i>	17
2.5.4. <i>Deep Learning</i>	17
2.5.5. Redes Neuronales Artificiales (ANNs)	18
2.5.5.1. Funciones de activación	19
2.5.5.2. Tipos de redes neuronales	22
2.5.5.2.1. Layer recurrent	22
2.5.5.2.2. Feed Forward	23
2.5.5.2.3. NARX	23
2.5.5.2.4. Elman backpropagation	24

2.5.5.2.5. Cascade forward backpropagation	24
2.5.5.3. Proceso de aprendizaje de las Redes Neuronales	24
2.5.5.4. Funciones de entrenamiento	26
2.5.5.4.1. Levenberg-Marquardt (LM)	26
2.5.5.4.2. Bayesian-Regularization (BR)	26
2.5.5.4.3. Resilient backpropagation (RProp)	27
2.5.5.4.3. Scaled conjugate Gradient (SCG)	27
3. METODOLOGIA	28
3.1. Método utilizado	28
3.2. Proceso de estimación de la red neuronal	29
3.2.1 Pretratamiento de datos	29
3.2.2 Redes neuronales	30
4. APLICACIÓN DE LA METODOLOGÍA	32
4.1. Pretratamiento de datos	32
4.1.1. Datos de partida	32
4.1.2. Aplicación	35
4.2. Redes neuronales	40
4.2.1. Elección del programa y creación de la red	40
4.2.2. Elección de tipo de red neuronal	42
4.2.3. Elección de la <i>training function</i>	43
4.2.4. Elección del número de capas y neuronas	44
4.2.5. Elección de las funciones de transferencia	47
4.2.6. Entrenamiento de la red y simulaciones	47
5. VALIDACIÓN Y ANÁLISIS DE LOS RESULTADOS	51
5.1. Análisis Red 50%	51
5.2. Análisis Red 10%	54
5.2.1. Análisis detallado de los errores	55
5.3. Comparación con el método NREL	61
5.3.1. Análisis de la robustez	63
5.4. Análisis de una nueva red neuronal	64
5.4.1. Red de 5 capas y 15 neuronas por capa	65
5.4.2. Caso de 6 capas y 15 neuronas	67
6. CONCLUSIONES	69
6.1. Conclusiones referidas a red neuronal a utilizar	69
6.2. Conclusiones referidas a la precisión de la red elegida	69
6.3. Conclusiones referidas a la mejoría respecto a métodos existentes	70

6.4. Recomendaciones.....	70
BIBLIOGRAFÍA	72

Glosario

- PV: *Photovoltaic*
- MPP: *Maximum Power Point*
- CC: Corriente continua
- CA: Corriente alterna
- LS-PVPP: *Large Scale Photovoltaic Power Plants*
- PCC: *Point of Common Coupling*
- TSO: *Transmission System Operator*
- ESS: *Energy Storage System*
- PPC: *Power Plant Controller*
- VRE: *Variable Renewable Energy*

1. Introducción

Una de las principales problemáticas de la energía solar es su dependencia de la meteorología que provoca intermitencias, dando lugar a periodos de máxima producción y otros de escasa o nula producción. Para cumplir el reglamento existente, y cada vez más estricto, que exige, entre otras cosas, el control de la frecuencia mediante inyecciones o recortes de potencia, existen diversas alternativas. Entre ellas destacan el uso de sistemas de almacenamiento y el trabajar por debajo de las capacidades máximas de la planta para ser capaz de inyectar o recortar potencia en caso de ser requerido. En este último caso es preciso conocer el valor de la potencia disponible en todo momento para así poder asegurar un porcentaje de capacidad de inyección o recorte de potencia.

Para conocer este valor existen métodos diversos. Uno de ellos es la utilización de redes neuronales, que es el que se va a desarrollar en este trabajo.

1.1. Objetivos generales

El objetivo general es el desarrollo de una metodología mediante redes neuronales para la estimación de potencia disponible de una planta fotovoltaica real, buscando minimizar el error de estimación para maximizar la producción de la planta, a la vez que se asegura el cumplimiento de los reglamentos.

1.2. Objetivos específicos

Para alcanzar el objetivo general se estudian distintas redes neuronales, considerando como variables el tipo de red neuronal, el tipo de *training function*, el tipo de función de transferencia y el número de capas y neuronas de dicha red. A partir de ellas:

- Se determinará qué combinación aporta la mayor precisión.
- Se analizará el error de la red elegida para poder comparar con otras metodologías existentes.
- Se obtendrá una solución a la variabilidad del error que pueda dar lugar al incumplimiento de los *grid codes*.
- Se extraerán conclusiones y se proporcionarán recomendaciones.

2. Estado del arte

Para poder comprender de forma correcta el contenido del presente trabajo se contextualiza el tema en el siguiente capítulo. Se aporta información sobre el entorno en que se aplica el trabajo para su mejor comprensión y entendimiento. Concretamente, se explicará de forma general la estructura de las plantas fotovoltaicas, así como los requisitos que actualmente se les imponen. También se aportarán conocimientos sobre las redes neuronales para el correcto entendimiento de las bases de las decisiones tomadas durante el trabajo.

2.1. Contexto

Con la crisis del petróleo en 1973 se empezaron a valorar alternativas a la energía proveniente de fósiles, invirtiéndose más en el desarrollo de las energías renovables. Este aumento de popularidad disminuyó desde finales de los años 80 hasta el año 2000, periodo en que ya se había estabilizado el petróleo. Posteriormente se volvió a popularizar el uso de energías renovables, destacando la fotovoltaica y la eólica. Recientemente, a partir de los años 2009-2010 la energía fotovoltaica se empezó a usar con mayor frecuencia notando un repunte en la instalación de paneles solares. Este aumento en los últimos años se debe a las múltiples ventajas, entre las cuales destaca la renovabilidad de la energía solar y eólica que las hace viables a largo plazo, evitando la dependencia de otras energías que son más contaminantes, reduciendo muy considerablemente el impacto medioambiental. Este aumento también va de la mano con la escasez de recursos naturales y el impacto y concienciación del efecto invernadero creado por las emisiones de CO₂, de las cuales dos tercios son debidos a la electricidad, la calefacción y el transporte [1]. Para solventar dichas problemáticas la generación eléctrica a partir de fuentes renovables se ha visto propulsada y, finalmente, en 2020 el porcentaje de energía producida por fuentes renovables (38%) logró superar el de fósiles (37%) (Figura 1).

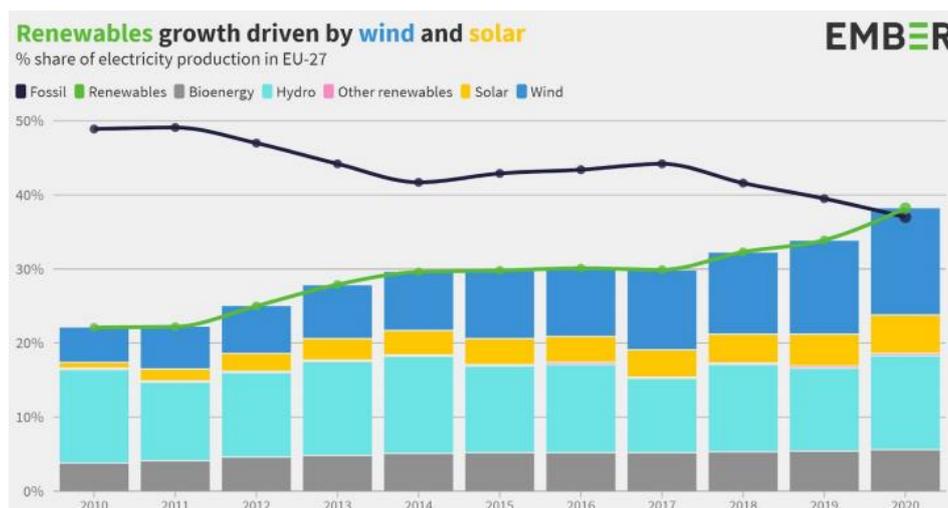


Figura 1. Comparativa entre el porcentaje de energía aportado por fuentes fósiles y renovables [2].

A medida que se han popularizado y estandarizado las instalaciones de energías renovables se han tenido que adaptar los requisitos de las redes (*grid codes*) para permitir su conexión a la

red. Estos requisitos aparecen debido a la irregularidad de generación por parte de las fuentes renovables de energía. A medida que han aparecido dichos *grid codes* se han adaptado las plantas de generación y se han implementado las nuevas teniendo en cuenta estos requisitos [3].

2.2. Descripción de una planta fotovoltaica

El presente trabajo se centra en las plantas de generación fotovoltaica por lo que se requiere conocer los componentes de dichas plantas, así como sus estructuras.

Existen dos tipos principales de plantas fotovoltaicas, un primer tipo que abarca las plantas de bajo y medio voltaje en el punto de conexión a la red o *Point of Common Coupling* (PCC); cuya capacidad va desde 1kW hasta unos pocos MW, y un segundo tipo que abarca las plantas de alto voltaje en el PCC; cuya capacidad va desde los 5MW hasta GW [3]. El primer tipo, debido a su menor voltaje, suele usarse para autoconsumo instalándose en los tejados de las viviendas y en edificios públicos pudiéndose, también, verter a la red toda la producción o únicamente la energía sobrante, en caso de que se produzca más de la que se consume. El segundo tipo suelen estar conectadas directamente al sistema de transmisión. Debido a los múltiples *grid codes* mencionados anteriormente estas plantas no suelen estar directamente conectadas a la red, sino que requieren controladores.

2.2.1. Elementos de las instalaciones

Las plantas fotovoltaicas están formadas por una serie de elementos que interconectados permiten la creación de la electricidad y su posible posterior inyección a la red. Dichos componentes dependen unos de otros y son necesarios para una correcta generación de energía fotovoltaica.

2.2.1.1. Interconexiones de PV modules

El principal elemento de una planta fotovoltaica son los paneles fotovoltaicos (paneles PV), los cuales son grupos de celdas PV montadas entre capas, generalmente de silicio, que captan la radiación solar y transforman los fotones en energía eléctrica. Dichas celdas, trabajando en su *Maximum Power Point* (MPP), crean un voltaje alrededor de los 0,5V. Este voltaje es demasiado bajo por lo que, para alcanzar un nivel de voltaje útil, decenas de celdas se interconectan en serie y se agrupan obteniendo las unidades comerciales conocidas como PV *modules*. En la Figura 2(a) se puede apreciar un módulo PV.

Los paneles fotovoltaicos operan en corriente continua (CC), mientras que la red eléctrica opera en corriente alterna (CA) a 50 o 60 Hz. Debido a esto, para poder conectar estos sistemas a la red hay que usar un inversor cuyas características de CC sean coherentes con las de salida de los paneles. Estas características engloban la corriente máxima, el voltaje mínimo, el voltaje nominal... Para obtener estas características y aumentar la potencia de salida, los PV *modules* se interconectan en serie o paralelo. De forma general se conectan inicialmente en serie, como en la Figura 2(b), obteniendo así el PV *string*, cuyo voltaje de salida es proporcional al número de módulos conectados. Una vez alcanzado el voltaje deseado, se conectan los PV *strings* en paralelo hasta obtener la corriente y la potencia deseadas dando lugar a los llamados PV *arrays* de la Figura 2 (c).

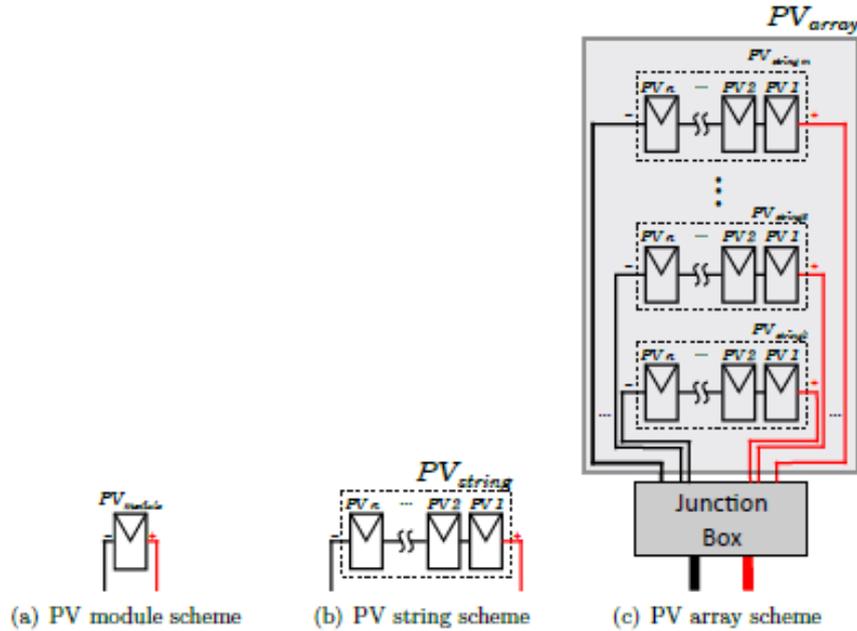


Figura 2. Interconexiones de PV modules [CITAR PHD]

2.2.1.2. Convertidores

Los convertidores son dispositivos electrónicos usados como elementos de interfaz entre dos sistemas eléctricos de distinta naturaleza de tensión. En el caso específico de aplicación fotovoltaica, sirven de interfaz entre el lado de CC del PV *module*, PV *string* o PV *array* y el lado de la red externa, usualmente de CA. Además, tienen la importante función de controlar la tensión de CC para que los paneles solares funcionen en el punto deseado, ya sea el MPP o por debajo de este, y así controlar la potencia reactiva en el lado de CA. Los inversores mencionados anteriormente son un tipo de convertidor.

Estos inversores pueden organizarse de diversas maneras (Figura 3) aportando diversas ventajas y desventajas según el caso.

- *Module integrated inverter*. Cada PV *module* requiere su propio convertidor CC-CA.
- *String inverter*. Cada PV *string* está conectado a la red mediante su propio convertidor CC-CA. Para este caso se requiere un convertidor CC-CA para cada PV *string*.
- *Multi-string inverter*. A diferencia del *string inverter*, distintos PV *strings* están interconectados mediante convertidores CC-CC que se conectan a un convertidor CC-CA. Así sólo se requiere de un convertidor CC-CA pero se añade la necesidad de añadir un convertidor CC-CC para cada PV *string*.
- *Central inverter*: Se usa un solo convertidor para cada PV *array*.

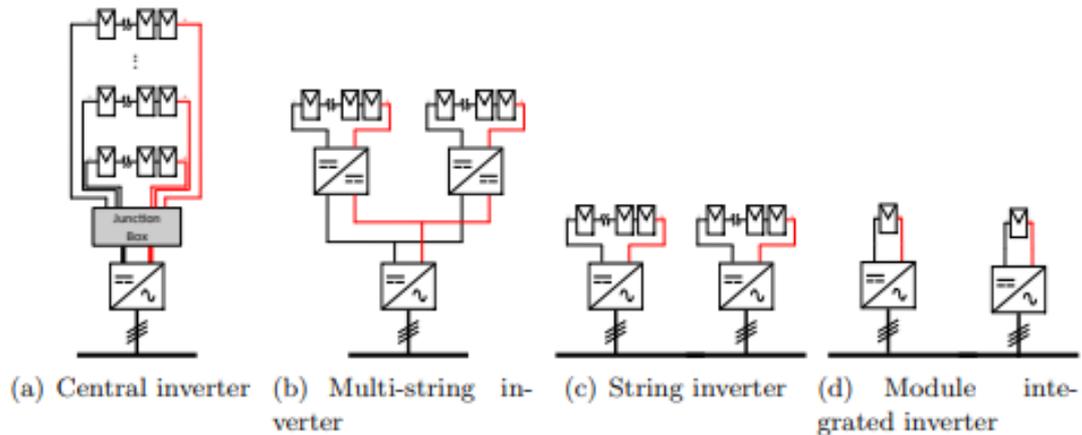


Figura 3. Estructuras de los inversores PV

Para saber cuál estructura es óptima hay que valorar que el uso de más controladores CC-CA implica más control y precisión a la hora de regular la tensión de CC. A cambio, implica un aumento significativo en el coste de inversión y de mantenimiento.

De forma general, el inversor más usado es el central debido a su bajo coste, a costa de una menor precisión y capacidad de regulación en comparación con los demás. Este inversor controla las potencias activa y reactiva. La energía generada depende de la tensión en CC por lo que se puede establecer un punto de consigna de la tensión en CC para así regular la potencia activa que se desea entregar, que puede ser la máxima o un valor fijo [3].

2.2.1.3. Transformadores

Generalmente las *Large Scale Photovoltaic Power Plants* (LS-PVPP) están conectadas a redes externas de alto voltaje para suministrar energía. La red encargada de transmitir la energía generada por los PV arrays a la red externa es la *collection grid*, cuya posición en el esquema se aprecia en la Figura 4. El voltaje de salida de los inversores PV suele estar por debajo de los 1000V por lo que se interconectan mediante dos etapas de transformación para poder llegar a conectarse a la red. Primeramente, se eleva la tensión de salida de los inversores hasta unos pocos kV según la tensión de la red de la *collection grid*. Esta transformación se puede realizar usando transformadores de dos o tres devanados, siendo estos últimos los más comunes. Seguidamente un transformador eleva su tensión hasta la tensión del punto de acoplamiento común (PCC) para así poder suministrarse a la red [3].

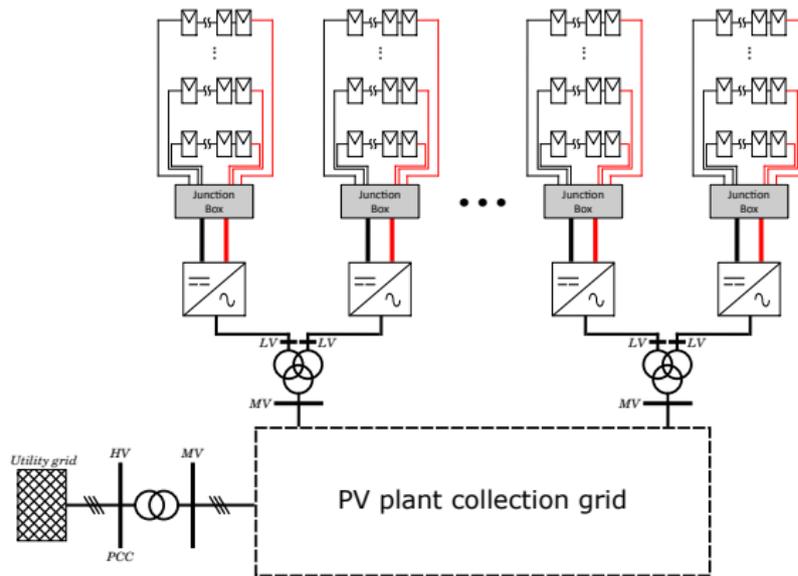


Figura 4. Configuración típica de LS-PVPP

Existen diversas configuraciones de *collection grids*, entre las cuales la más común y óptima es la de anillo, cuya estructura se puede ver en la Figura 5. Esta configuración permite que, en caso de que falle algún componente de un transformador, este no cause pérdidas mayores que las suyas propias debido a que no corta la *collection grid*, así evitando aislar los demás transformadores por el fallo de uno solo. Esta configuración requiere de una alta inversión en cableado.

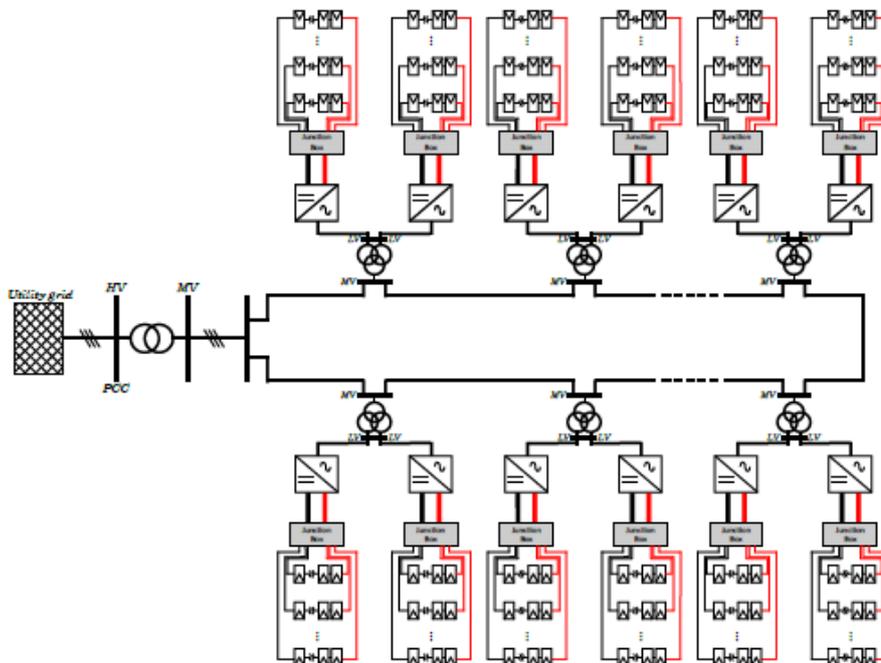


Figura 5. Configuración de anillo

2.2.1.4. Controlador de la planta (PPC)

El *Power Plant Controller* (PPC) es un elemento central de las LS-PVPP que presta asistencia con los *grid codes* (2.3) permitiendo inyectar correctamente a la red la electricidad producida. El PPC toma las consignas impuestas por el *Transmission System Operator* (TSO) y los requisitos en el PCC, y es a partir de estos que decide cómo actuar coordinando todos los generadores. En caso de que haya *Energy Storage System* (ESS), es el PPC el que se encarga de interactuar con dicha unidad para que, en caso de necesitar inyectar más potencia, se pueda hacer.

Para su aplicación existen dos maneras de implementarlo [4]:

2.2.1.4.1. Arquitectura de control centralizada

La arquitectura de control centralizada es aquella en que el PPC actúa como elemento central que, mediante la información externa como la consigna del TSO y los datos de la planta, como las tensiones y potencias, las compara para actuar en caso de que se requiera. Las ordenes tomadas por el PPC se transmiten directamente a los inversores para ser aplicadas. Este tipo de controlador es de fácil instalación y requiere una menor inversión económica, aunque se sacrifica tiempo de respuesta debido a que, como se aprecia en el esquema de la Figura 6, el PPC está considerablemente lejos de los inversores.

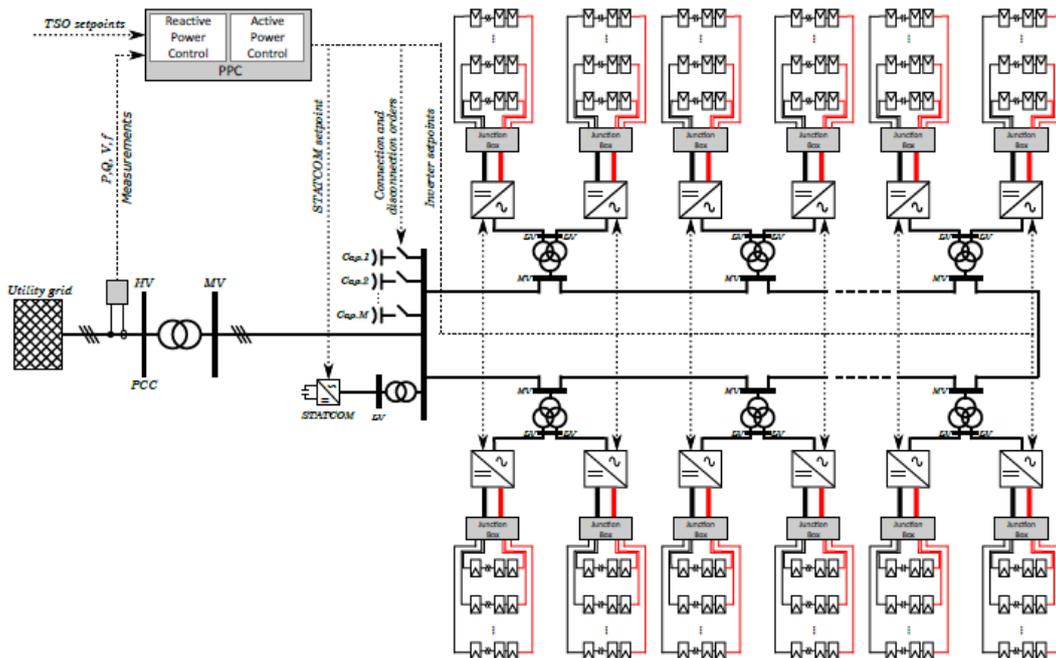


Figura 6. Esquema de la arquitectura de control centralizada

2.2.1.4.2. Arquitectura de control distribuida

En este caso, a diferencia de la arquitectura de control centralizada, hay múltiples controladores implementados de forma individual en cada inversor, como se aprecia en la Figura 7. Aunque esta arquitectura suponga una mayor inversión económica respecto a la centralizada, también aporta una mayor velocidad de respuesta ante los cambios de consigna. Su principal desventaja

es que, al no recibir información global de la planta, como las potencias en el PCC, las decisiones se toman a nivel local. Al no tomar como referencia las medidas en el PCC, no se toman en cuenta las pérdidas de potencia que suceden entre el controlador y el PCC. Estos errores podrían conllevar que no se cumplieran algunos *grid codes* por lo que se suele descartar esta opción.

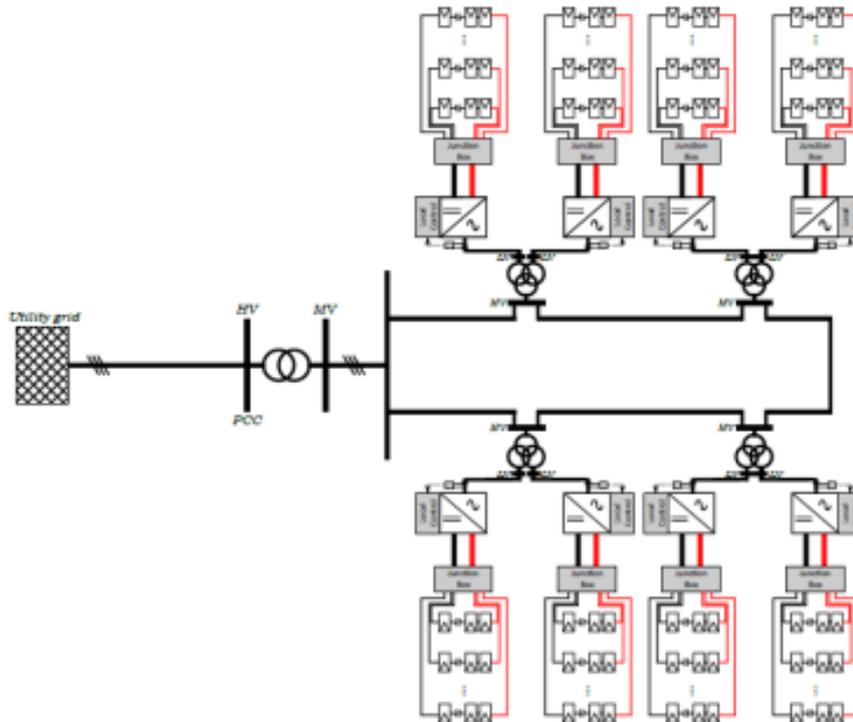


Figura 7. Esquema de la arquitectura de control distribuida

2.3. Grid Codes

Los *grid codes* son una serie de especificaciones técnicas aplicadas a todos los participantes activos en el sistema eléctrico que estén conectados a la red pública que aseguran el buen funcionamiento de esta. Su propósito es cubrir las circunstancias habituales y extraordinarias de las centrales eléctricas [5].

Estos códigos varían según el país, aunque se pretende armonizar dichos requisitos con la creación de *grid codes* regionales, que no reemplazan a los nacionales, sino que proporcionan un marco común para los requisitos mínimos que deben cumplir todos los *grid codes* nacionales. En el caso de Europa estos códigos son los ENTSO-E.

Los *grid codes* son de vital importancia en el caso de las *Variable Renewable Energy* (VRE) como es el del presente trabajo, una planta fotovoltaica destinada a la generación de electricidad para la red. Esto es debido a la alta variabilidad a la hora de producir energía ya que dependen de la meteorología de la zona en que se encuentren las centrales. Esto supone una inyección irregular de energía a la red que puede llegar a dar problemas [6].

Estos códigos se dividen en 4 tipos:

- Códigos de conexión. Establecen requisitos para las instalaciones de generación, demanda y transporte que se conectan a la red.
- Códigos de operación. Establecen reglas y procedimientos para la gestión de la red y la operación del sistema en situaciones de emergencia y reposición del servicio.
- Códigos de mercado. Marcan las pautas para la creación de un mercado interior de la energía interconectado y funcional.

Los códigos de mayor interés en el presente trabajo son los de operación. Estos se pueden subdividir en 3 tipos:

- Requisitos de frecuencia y potencia activa: En caso de que se produzcan desequilibrios entre la potencia generada y la requerida en la red eléctrica se producen variaciones de frecuencia nocivas para los equipos eléctricos conectados. Para solventar los problemas ocasionados por estas variaciones de frecuencia se recorta o inyecta potencia activa.
- Requisitos de tensión y potencia reactiva: En caso de que la tensión de conexión a red esté fuera de los límites de las tolerancias, la central ha de ser capaz de inyectar o absorber potencia reactiva.
- Requisitos de apoyo frente a fallos: En caso de fallos en la red eléctrica, como caídas de tensiones y fallos de sincronización, se requiere que las centrales apoyen a la red mediante inyecciones de potencia reactiva para incrementar la tensión global de la red evitando así apagones en cascada de las centrales de generación.

El primer tipo de requisitos afecta a la potencia activa generada mientras que los otros dos afectan a la potencia reactiva. El presente trabajo se aplica al primer tipo de requisitos por lo que se estudian con mayor profundidad [7].

Los principales requisitos que afectan la potencia activa son:

- *Power curtailment*

El *power curtailment* consiste en la reducción de la potencia activa máxima que la central fotovoltaica produce, en caso de que sea inferior a la capacidad de la planta, para así solventar problemas de congestión de red o para equilibrar la oferta y demanda. Para ello, es importante definir la potencia activa máxima que la central fotovoltaica produce. Las centrales tienden a intentar alcanzar su *setpoint* para maximizar la producción e ingresos, así que generalmente trabajan maximizando la producción hasta que se les requiere que limiten su producción. En este caso, como se trata de reducir la generación de potencia activa no se necesita ningún tipo de reserva de potencia. La potencia entregada por la planta bajo *power curtailment* se calcula como el producto del factor de *curtailment* (f_c) y la potencia disponible de la planta. Este f_c habitualmente oscila entre el 10% y 90%.

- Regulación de frecuencia

La regulación de frecuencia marca como tienen que reaccionar las plantas fotovoltaicas en caso de que la frecuencia de red se salga de sus límites de tolerancia establecidos por el TSO.

Existen dos posibles casos:

- *Over-frecuency*

En el caso de haber *over-frecuency*, la frecuencia se encuentra por encima de las tolerancias, entre f_3 y f_{max} en la Figura 6, por lo que puede llegar a ocasionar problemas en el sistema. Para prevenir el sistema de dichos problemas se reduce la potencia entregada de forma proporcional al aumento de frecuencia. Al igual que en el caso del *power curtailment*, la central reducirá su producción operando por debajo de sus capacidades. También existe un f_c que oscila entre el 10% y 90% [8].

- *Under-frecuency*

En el caso del *under-frecuency*, la frecuencia se encuentra por debajo de las tolerancias, entre f_{min} y f_2 en la Figura 8, por lo que también puede ocasionar problemas en el sistema. En este caso se procede de manera similar al anterior, pero en vez de recortar la potencia entregada, esta debe aumentar. En este caso, la dificultad reside en cómo conseguir este aumento de potencia. En la mayoría de los países el máximo porcentaje de potencia que hay que inyectar es del 10% o menos, siendo en Europa entre 1.5 y 10% según el ENTSO-E [7].

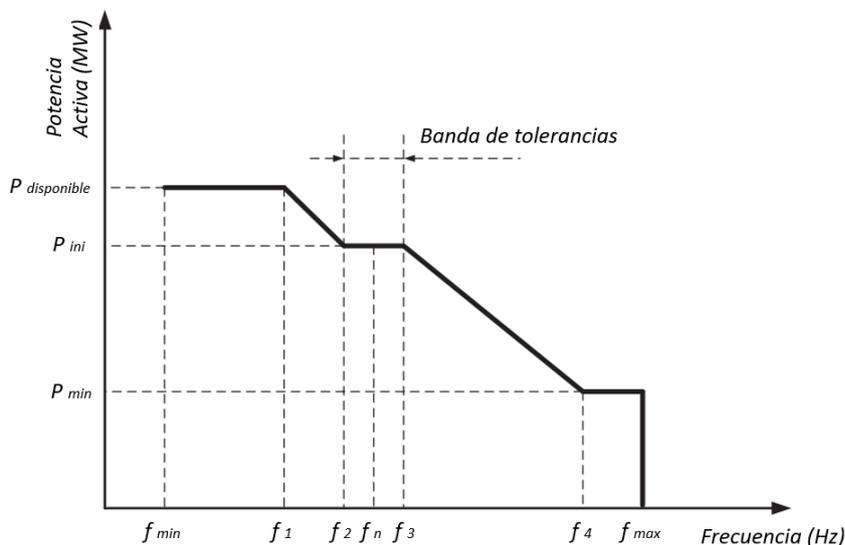


Figura 8. Relación entre la Potencia Activa y la Frecuencia para la regulación de frecuencia

Dentro de las múltiples posibilidades para conseguir el aumento de potencia destacan dos:

- Almacenamiento de energía

Esta alternativa permite que la planta trabaje a su máximo potencial por lo que implica su máxima producción de energía. Únicamente consiste en almacenar la energía en ESS que, en caso de que se produzca *under-frecuency*, se pueda inyectar la potencia que falte a través de estas baterías. La principal desventaja de este método es el gran coste económico de los ESS y de su mantenimiento [7].

En el caso de redes robustas que sufran *under-frecuency* de manera muy puntual esta opción es la más adecuada.

- Trabajando por debajo del MPP

Esta alternativa se suele aplicar en redes cuya estabilidad sea poco robusta y que sean susceptibles a padecer *under-frequency*. Esta alternativa propone trabajar de manera habitual produciendo energía por debajo, en porcentaje, de la capacidad máxima de producción del sistema para que, cuando sea necesario inyectar más potencia, baste con aumentar la producción al máximo sin necesidad de ESS. En la Figura 9, más concretamente en el tramo entre t_1 y t_2 , se puede apreciar el fenómeno. Este método ahorra en costes de inversión, pero implica una menor producción cuando se trabaja de manera normal.

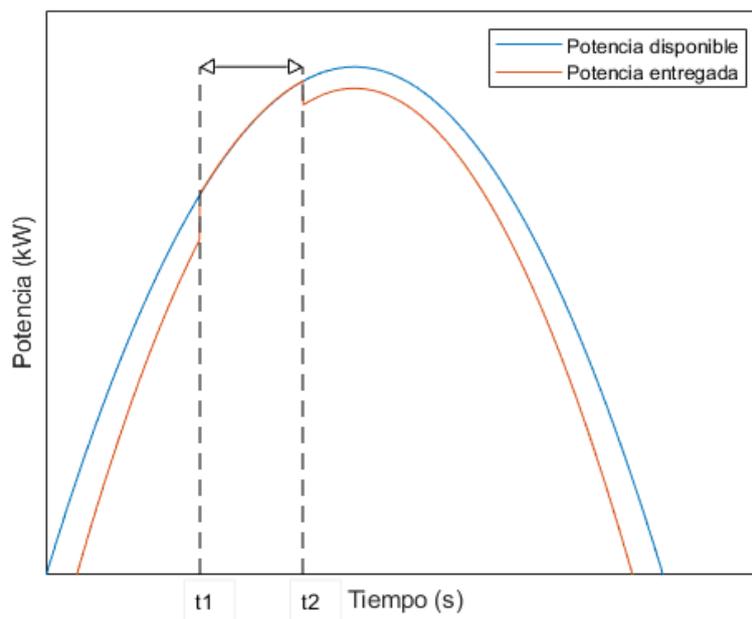


Figura 9. Ejemplo del fenómeno *under frequency*

La dificultad que reside en la aplicación de este método aparece a la hora de conocer la potencia disponible de la planta en todo momento ya que se conoce de manera exacta la potencia que se produce, que no tiene por qué ser la disponible, como sucede cuando hay *power curtailment*.

En el caso de la Figura 10, se puede apreciar como, entre el tiempo 0 y t_2 , la potencia consigna es inferior a la máxima potencia disponible de la planta, aunque solo produce *curtailment* entre t_1 y t_2 . En este último tramo se desconoce la potencia disponible debido a que la potencia entregada es limitada por la potencia consigna del TSO, a diferencia del primer tramo, en el que, aunque la potencia consigna del TSO sea menor que la potencia máxima total de la planta, la potencia disponible aún no ha llegado a superar dicho límite. Posteriormente, la potencia consigna del TSO aumenta y la central procede a producir su potencia disponible de nuevo. En este caso, la potencia conocida en el periodo entre $t=0$ y t_1 es igual a la potencia. Entre t_1 y t_2 la potencia conocida es igual a la potencia consigna del TSO, por lo que se desconoce la potencia disponible. Finalmente, a partir de t_2 la potencia conocida vuelve a ser la potencia disponible.

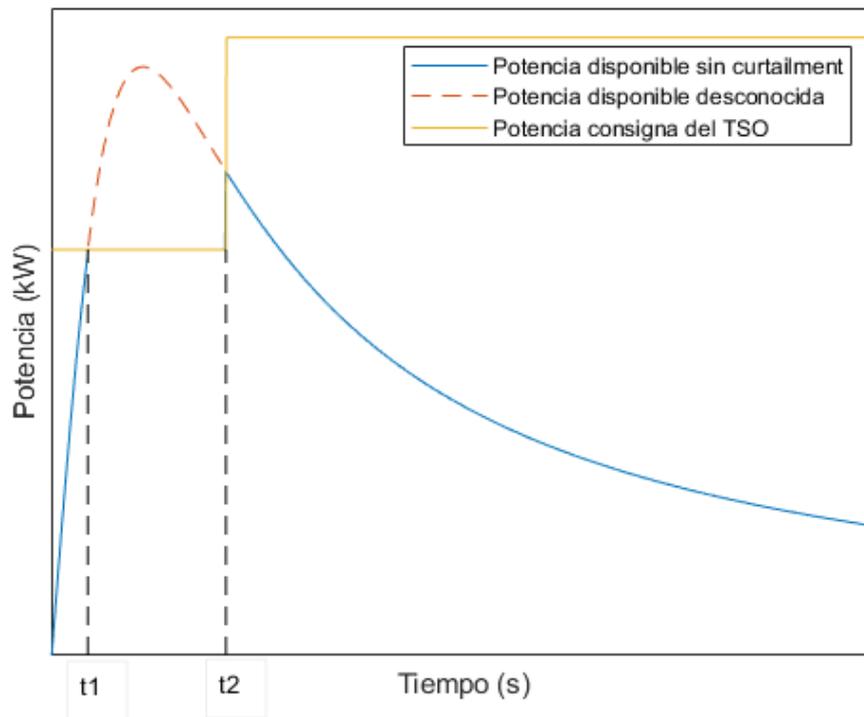


Figura 10. Ejemplo de power curtailment

2.4. Métodos de estimación de potencia

Como se menciona anteriormente, la dificultad de trabajar por debajo del MPP reside en conocer la potencia disponible de la planta en todo momento. Debido a la variabilidad de la generación fotovoltaica, esta no puede ser calculada de forma sencilla a partir de la capacidad del propio panel fotovoltaico. La irradiación que recibe varía a medida que avanza el día y según las condiciones meteorológicas. En este caso la predicción es instantánea, no se realizan predicciones ni a largo ni a medio plazo debido a que interesa una gran precisión que no se podría obtener en estas.

Para solventar este problema aparecen diversas formas de estimar correctamente la potencia disponible, que se explican a continuación.

2.4.1. Estimación mediante análisis meteorológico

Como se ha mencionado, la meteorología hace que la potencia disponible varíe constantemente, por lo que, para poder tomar en cuenta dichos cambios, se plantea la instalación de sensores meteorológicos por toda la planta que midan la irradiación y la temperatura ambiente. Mediante las medidas que toman los sensores y las características de los paneles solares se calcula la potencia disponible de la planta. Esta alternativa aporta mucha precisión, velocidad de respuesta ante cambios meteorológicos y robustez, aunque también supone la instalación de muchos sensores que implican una mayor inversión y mantenimiento

[9]. Para reducir el número de sensores instalados también se pueden localizar unos pocos sensores distribuidos uniformemente por la planta para posteriormente predecir con inteligencia artificial y redes neuronales la potencia disponible. En este caso se requiere una menor inversión, aunque es necesaria una gran cantidad de datos históricos para poder entrenar dicha red neuronal.

2.4.2. Estimación mediante inversores dedicados

Otra alternativa para poder estimar la potencia disponible de la planta es dedicar un porcentaje de los inversores a trabajar en MPP constantemente para extrapolar sus medidas a los demás inversores. De esta manera también se toman en cuenta variables externas como el efecto de la suciedad de los paneles. Aunque para predicciones diarias se ha extendido el uso de la estimación mediante análisis meteorológico, para predicciones de menos de 4h de plazo se ha demostrado que la precisión se mejora considerablemente si se aplican estadísticas [10].

2.4.3. Método NREL: *Highly Accurate Method for Real-Time Active Power Reserve Estimation for Utility-Scale Photovoltaic Power plants*

En caso de que el cielo esté despejado, con un solo inversor se podría extrapolar su valor a todos los inversores de la planta, por lo que con tener un solo inversor trabajando a MPP se podría multiplicar su potencia disponible por el número de inversores totales y así se sabría la potencia disponible total de la planta. Sin embargo, en condiciones de nubosidad variable podría haber ciertos inversores con menos irradiancia que otros que no se vieran afectados por dicha nubosidad. Para poder solventar la problemática de la nubosidad y otros factores que alteren la homogeneidad de irradiancia se crean zonas de control virtuales, como las mostradas en la Figura 11, en que haya un inversor dedicado que determine el valor aproximado de potencia disponible de todos los inversores de dicha zona. Para ello, hay diversas combinaciones y estructuras para elegir la localización de los inversores dedicados para maximizar el alcance de estos [11].



Figura 11. Esquema de planta fotovoltaica dividida en sus zonas de control [11]

En este caso la potencia disponible total de la planta sería la suma de las potencias disponibles de cada zona de control, y la potencia disponible de cada zona de control sería la potencia disponible de su inversor dedicado multiplicada por el número total de inversores.

La potencia entregada de la red sería la suma de las potencias entregadas de cada zona de control y, estas potencias serían la suma de las potencias entregadas por los inversores que trabajan por debajo del MPP más la potencia disponible del inversor dedicado.

2.4.4. Método de aplicación de redes neuronales

En caso de tener grandes cantidades de datos de la planta, se puede aplicar inteligencia artificial junto con el *big data* recogido. Más concretamente, se puede aplicar *machine learning* y redes neuronales para que, mediante los datos recogidos de los inversores dedicados, entrenar dicha red neuronal. Una vez entrenada la red neuronal con tan solo tener los datos instantáneos de los inversores dedicados se puede estimar la potencia total disponible de la planta. En este caso también se requiere de las mismas zonas de control virtuales con sus inversores dedicados colocados de forma estratégica para abarcar el máximo espacio posible y así mejorar la precisión de la predicción.

El presente trabajo se centra en la aplicación de estas redes neuronales para la predicción de la potencia disponible de la planta por lo que se analizan en más profundidad en el siguiente capítulo.

2.5. Inteligencia artificial y *Big Data*

La inteligencia artificial y el *big data* son la base de una gran variedad de innovaciones tecnológicas que han dado forma al entorno digital actual. La función de su combinación es sacar el máximo valor posible a la gran cantidad de datos que se generan. Su gran potencial las hace interesantes a la hora de aplicarlas a diferentes proyectos de predicción como el que presenta este trabajo.

2.5.1. Big Data

El concepto de *Big Data* engloba muchos términos y conceptos cuyo objetivo fundamental es extraer valor de la inmensa cantidad de datos que se generan y recogen. Se puede definir como las cuatro V, que hacen referencia al gran Volumen de datos que se tratan, a la Velocidad de procesamiento de dichos datos, a la Variedad de formas que pueden tomar estos y al Valor que se obtiene con la información que se puede extraer de ellos.

El *Big Data* aporta una capacidad de procesamiento y obtención de información muy valiosa, pero puede llegar a crear algún conflicto. El exceso de datos es una problemática que puede ralentizar y obstaculizar las tareas, además de tener un coste por su almacenamiento. Además, los datos almacenados pueden ser de gran valor y/o privados por lo que el valor de dichos datos y su vulnerabilidad puede ser objetivo de ciberataques que pueden usar los datos para dañar a su propietario.

Dependiendo de la información obtenida podemos aplicar 3 tipos distintos de analíticas [12].

- Analítica descriptiva. Consiste en analizar y comprender el estado actual y pasado mediante conjuntos de datos históricos.
- Analítica predictiva. Consiste en estimar aquellos valores desconocidos mediante modelos estadísticos avanzados. Se construye tomando la analítica descriptiva como base y generalmente se usa en la predicción de valores futuros.
- Analítica prescriptiva. A partir de las dos anteriores, es la encargada de recopilar datos, recomendar acciones y prever qué impacto tendrán para facilitar y optimizar la toma de decisiones.

2.5.2. Inteligencia artificial

La inteligencia artificial es una recreación de lo que sería la inteligencia humana capaz de, mediante bases de datos y algoritmos para reconocer patrones, tomar decisiones lógicas y óptimas. Esta, aplicada al *Big Data*, proporciona grandes beneficios como pueden ser la detección de desviaciones y capacidad de reconocimiento de patrones [13].

2.5.3. *Machine learning*.

Dentro de la inteligencia artificial existen diversas ramas entre las cuales destaca el *machine learning*, la cual permite que los algoritmos aprendan sin ser expresamente programados para ello.

Existen tres distintos enfoques [14]:

- *Supervised learning*. En el cual el operador proporciona al algoritmo un conjunto de datos conocidos con los inputs y outputs deseados y el algoritmo encuentra un método para determinar cómo llegar a esos outputs a partir de los inputs. Al conocer el output deseado el algoritmo puede calibrarse múltiples veces hasta conseguir reducir al máximo los parámetros de error.
- *Unsupervised learning*. Partiendo de los valores que conforman los inputs, el algoritmo identifica patrones y determina correlaciones mediante el análisis de dichos inputs. A medida que aumenta el tamaño de datos disponibles mejora la capacidad de tomar decisiones sobre los mismos.
- *Reinforced learning*. También conocido como aprendizaje por ensayo y error. El algoritmo aprende observando el mundo que le rodea y cómo cambia dependiendo de sus acciones.

2.5.4. *Deep Learning*

Dentro de las ramas del *machine learning*, la que más se asemeja a lo que sería la organización del sistema nervioso humano es el *Deep Learning*, el cual simula el comportamiento humano mediante varias capas de algoritmos de redes neuronales [15]. Esta arquitectura aporta la mayor precisión con respecto a los algoritmos clásicos de *machine learning* como los algoritmos de regresión, los bayesianos o los de agrupación.

2.5.5. Redes Neuronales Artificiales (ANNs)

Las ANNs buscan emular el comportamiento de una red neuronal humana para conseguir que una máquina sea capaz de “pensar” y realizar procesos con cierta “inteligencia”. Estas redes neuronales están inspiradas en la estructura del sistema nervioso humano en que la base es la neurona. Las neuronas humanas se encuentran interconectadas entre sí y se comunican mediante impulsos eléctricos [15].

Una neurona humana tiene tres partes principales: Las dendritas, cuya función es recibir los estímulos de entrada, el cuerpo de la neurona, encargado de procesar los estímulos de entrada, y el axón, el cual emite estímulos de salida a las dendritas de otras neuronas. Estas partes se pueden ver en la Figura 12.

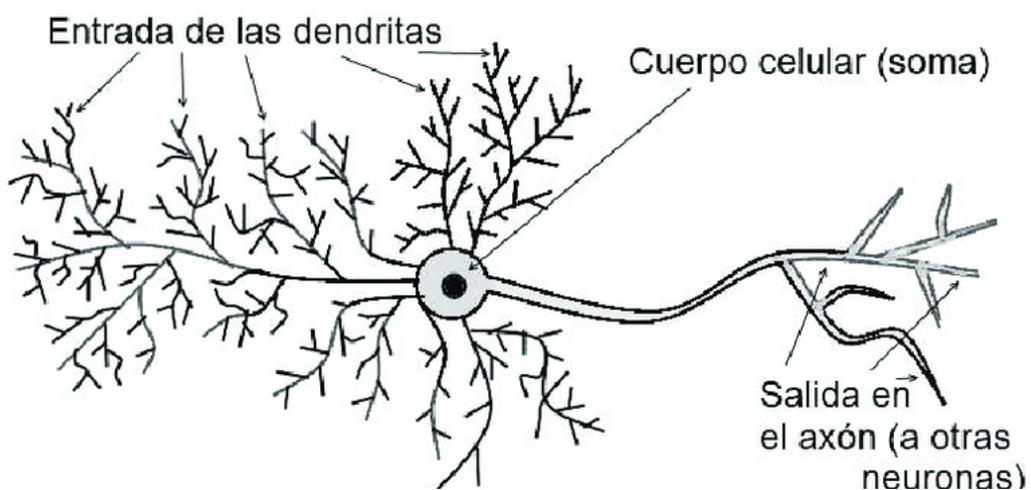


Figura 12. Esquema de una neurona [16]

Para memorizar y aprender se activan distintas conexiones entre neuronas para obtener la salida deseada mediante combinaciones de las señales de entrada y las neuronas.

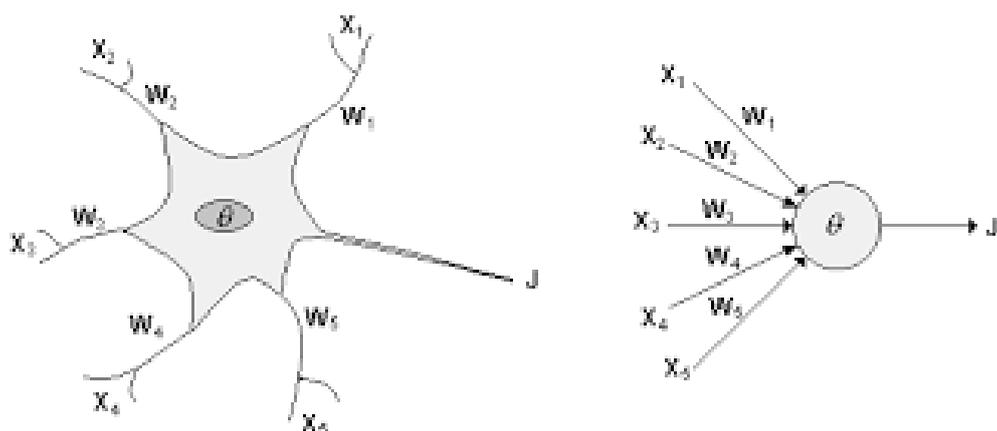


Figura 13. Analogía entre una neurona real y una artificial [13]

En la Figura 13 podemos apreciar algunas analogías entre las redes neuronales artificiales y las redes neuronales biológicas además de las partes del esquema de una neurona artificial [13].

- Los inputs X_i equivalen a las señales capturadas por las dendritas

- La función de activación equivale al cuerpo de la neurona. Esta función permite modelar los patrones que poseen los datos introducidos y se aproximan por diferentes funciones genéricas como pueden ser la tangente hiperbólica, la función ReLU, la función lineal...
- El output J equivale a las señales producidas en los axones y representan el valor final obtenido por dicha neurona.
- Los pesos o *weights* de las conexiones son un valor comprendido entre -1 y 1 que marca la influencia de una neurona individual en la salida de la neurona siguiente. Es decir, marca la influencia de un output sobre el input de la siguiente neurona.
- El sesgo o *bias* es un valor comprendido entre -1 y 1 que controla qué tan predispuesta está la neurona a disparar un 1 o un 0 independientemente de los pesos. Permite desplazar la función de activación hacia la izquierda o hacia la derecha.
- Las capas o *layers* se dividen en 3 tipos, cuya estructura es la de la Figura 14. La capa de entrada, la cual depende de la cantidad de inputs; la capa de salida, la cual depende del número de outputs requerido y las capas ocultas, las cuales se ubican entre la capa de entrada y la de salida. De estas capas ocultas no se tiene información y son la base del *Deep learning*. A medida que aumentan las capas ocultas aumenta el coste computacional y, generalmente, la precisión a la hora de detectar patrones en los inputs.

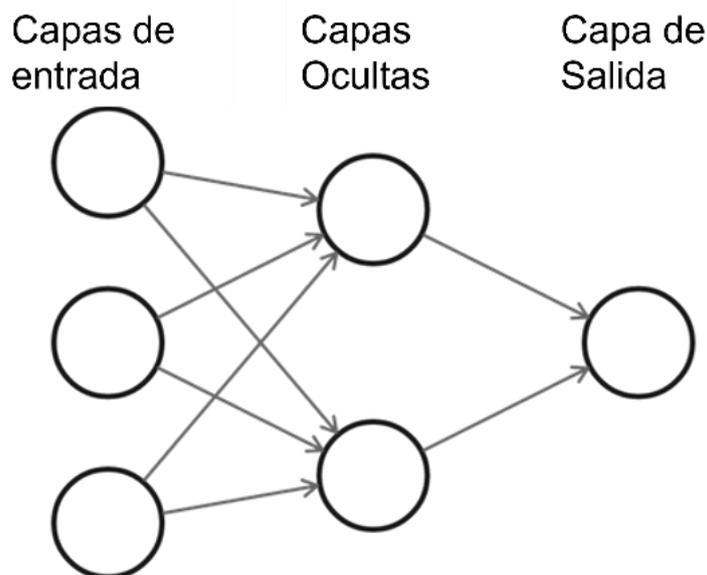


Figura 14. Estructura de las capas de una neurona [17]

2.5.5.1. Funciones de activación

Las funciones de activación devuelven un output generado por la neurona a partir de un conjunto de inputs [18]. Existen dos tipos de funciones de activación: lineales o no lineales.

- **Función Lineal.** En esta función el output es proporcional al input, en la Figura 15 se grafica dicha función. Presenta una desventaja y es que dicha función no es derivable.

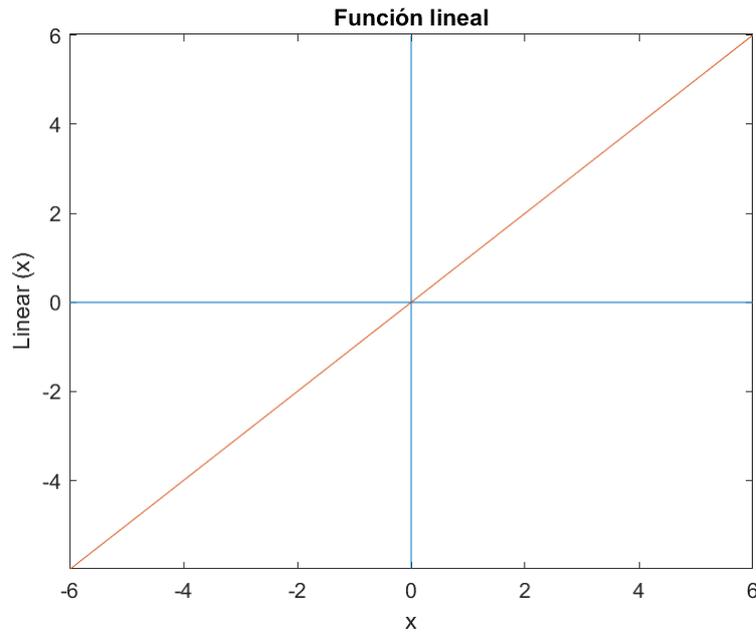


Figura 15. Representación de la función lineal

Funciones no lineales:

- **Función Umbral.** Es una función escalón la cual se suele usar cuando se quiere clasificar o cuando se tiene salidas categóricas. Dicha función tampoco es derivable. En la Figura 16 se aprecia cómo la salida sólo toma dos valores.

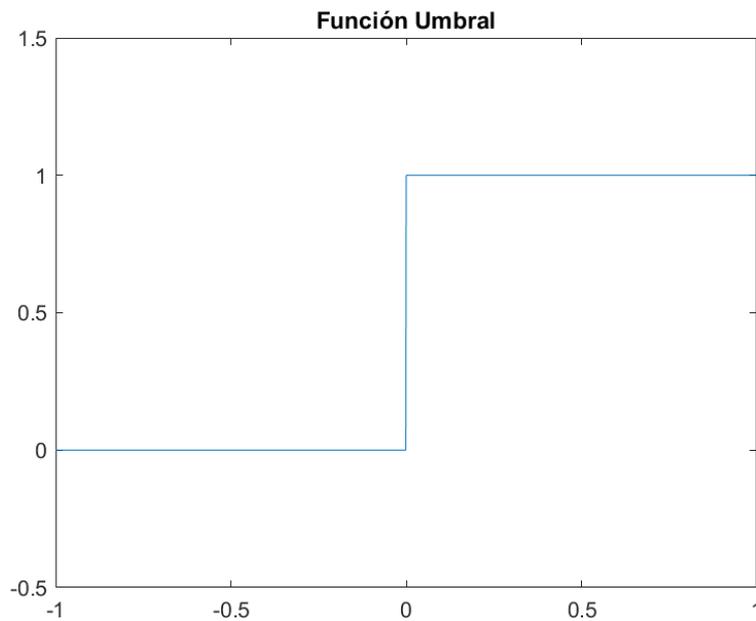


Figura 16. Representación de la función umbral

- **Función Sigmoide.** El output de esta función está comprendido entre los valores 0 y 1 por lo que se puede interpretar como una probabilidad. Es una función similar a la función Umbral con la diferencia de que esta cambia de valor 0 a valor 1 de manera continua, como se puede ver en la Figura 17. Esta función se rige por la Ecuación 1. También se puede usar para clasificar en dos categorías. Su parte negativa es que para valores de input muy negativos o positivos puede estancar el entrenamiento de la neurona.

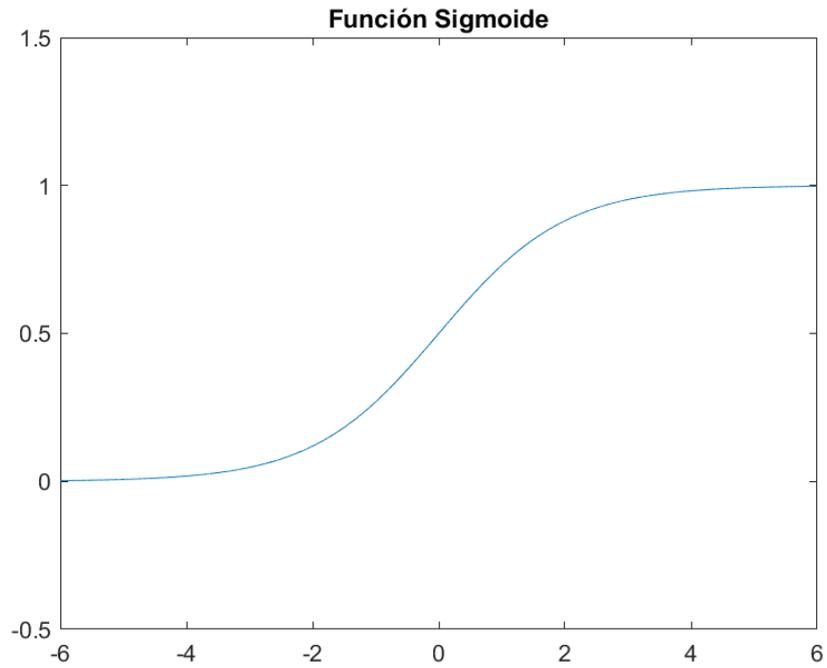


Figura 17. Representación de la función sigmoide

$$f(x) = \frac{1}{1+e^{-x}} \quad (1)$$

- Función tangente hiperbólica. Esta función de activación tiene un rango de valores de output comprendidos entre el -1 y el 1 y, a diferencia de la función Sigmoide, sí está centrada, como observamos en la Figura 18. Esta función presenta la misma desventaja respecto a los valores muy negativos o positivos que la función sigmoide. Esta función se rige por la Ecuación 2.

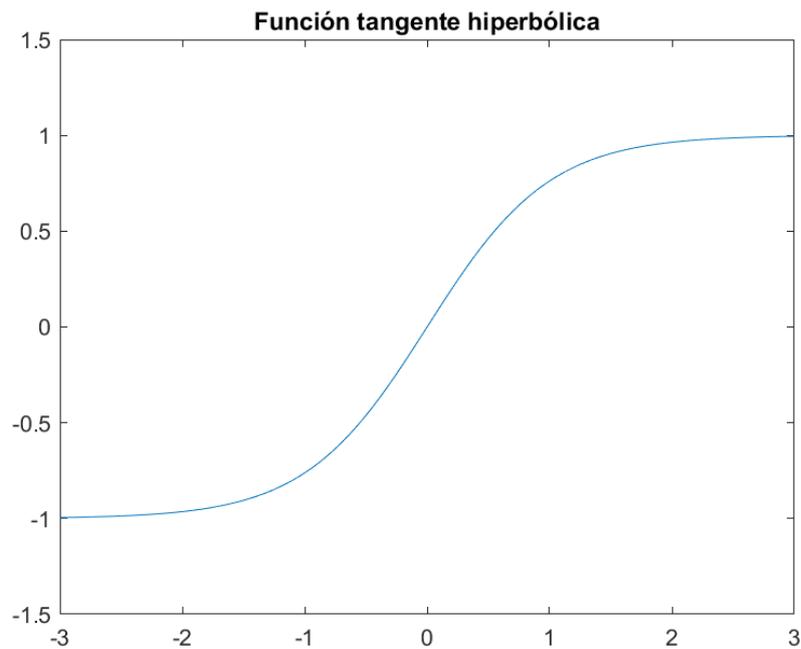


Figura 18. Función tangente hiperbólica

$$f(x) = \frac{2}{1+e^{-2x}} - 1 \quad (2)$$

- **Función ReLu.** Esta función tiene por output el valor 0 siempre que el input sea negativo. Es la función más usada debido a que permite un aprendizaje muy rápido. Cuando el output de la función es 0 y su derivada también, provoca la muerte de neuronas. Esto puede ser una ventaja o desventaja según el caso. Para solventar la muerte de neuronas se usa la función Leaky ReLu, la cual permite prevenir la existencia de dichas neuronas mediante una pequeña pendiente que existe para valores negativos del input. En la Figura 19 se pueden apreciar ambas funciones y sus diferencias.

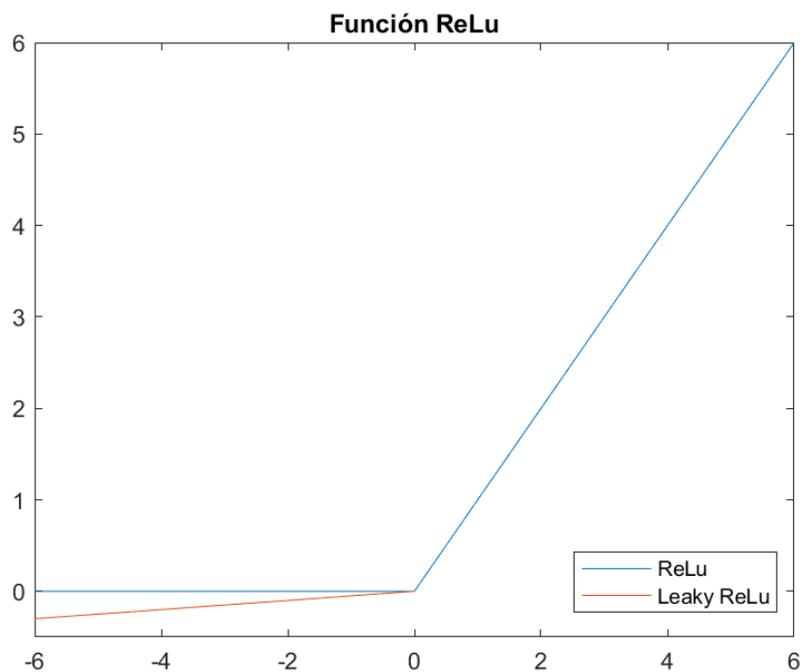


Figura 19. Representación de las funciones ReLu y Leaky ReLu

2.5.5.2. Tipos de redes neuronales

Según el esquema de interacciones entre capas de una red neuronal podemos distinguir diversos tipos de redes neuronales. Estas estructuras benefician a diferentes naturalezas de datos según el caso.

2.5.5.2.1. Layer recurrent

Esta estructura es muy apropiada para *TimeSeriesData* debido a que tiene una memoria con la que recuerda el valor previo por lo que permite un mejor análisis y predicción de patrones temporales [19]. En cada instante la neurona recibe el input pertinente y también el output de la neurona anterior por lo que puede usar esa información para calibrarse mejor. Esta estructura se puede apreciar en la Figura 20.

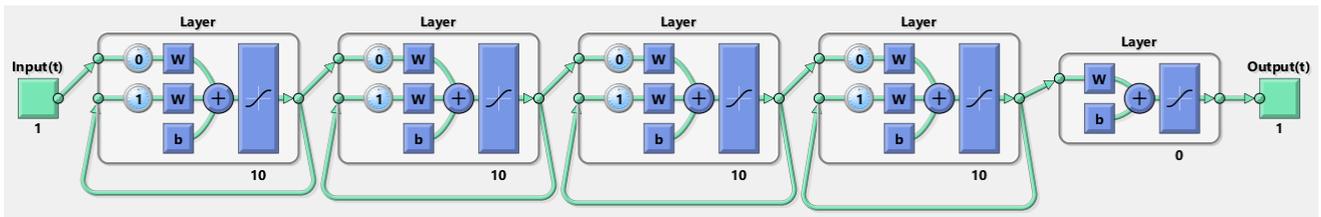


Figura 20. Estructura de la red recurrente en Matlab®

2.5.5.2.2. Feed Forward

En este caso, no hay ninguna memoria que recuerde el valor previo, las conexiones entre capas no forman ningún ciclo. En la estructura *feed forward* la información fluye a través de las neuronas y capas de manera unidireccional, como vemos en la Figura 21, de manera que dicha información no puede pasar nunca más de una vez a través de una misma neurona antes de generar el output [13].

Es un tipo de red más sencillo que requiere de un menor tiempo computacional, por ello es de los modelos más utilizados y populares para aplicaciones prácticas. Con una configuración de dos capas y un número suficiente de neuronas se puede aproximar cualquier función continua a un grado de precisión arbitrario [20].

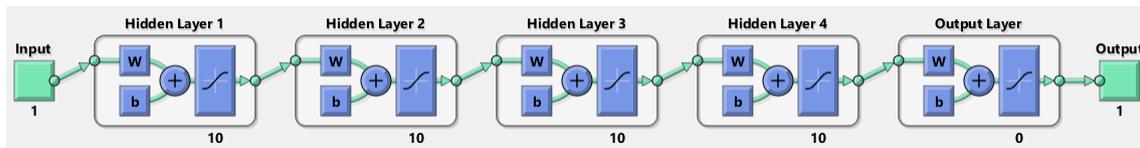


Figura 21. Estructura de la red feed forward en Matlab®

2.5.5.2.3. NARX

Las NARX se basan en el modelo lineal *Autoregressive with Extra Input* (ARX) que se usa habitualmente en la modelización de series temporales. En este caso el output de cada neurona depende de los outputs e inputs de todas las neuronas anteriores [21]. Este tipo de red neuronal se suele aplicar a modelado de sistemas dinámicos no lineales y a series temporales caóticas. La estructura de esta red neuronal es la de la Figura 22.

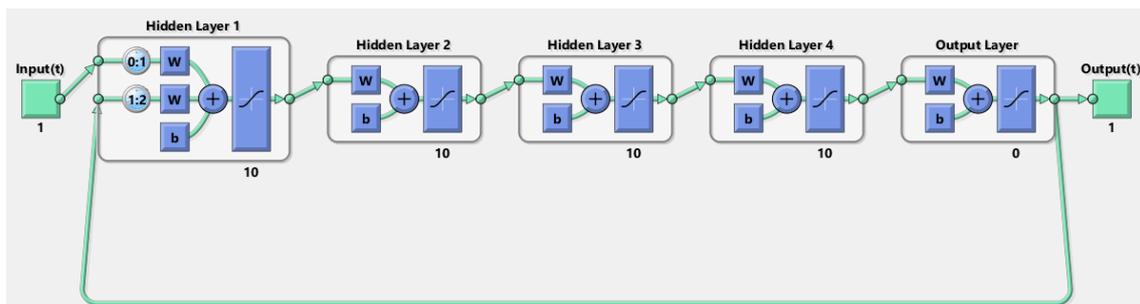


Figura 22. Estructura de la red NARX en Matlab®

2.5.5.2.4. Elman backpropagation

La red neuronal de Elman es un tipo de red neuronal recurrente que tiene la misma estructura que la *layer recurrent*, como podemos apreciar en la Figura 23, aunque en este caso las neuronas no reciben el output directamente, sino que reciben la activación de las neuronas ocultas [22].

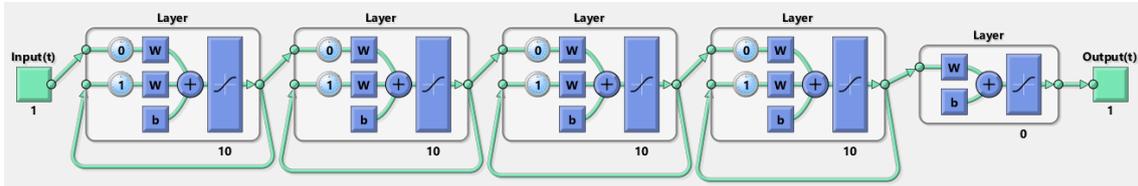


Figura 23. Estructura de la red Elman backpropagation en Matlab®

2.5.5.2.5. Cascade forward backpropagation

Este modelo es muy similar a las redes *feed forward*, pero añadiéndole un *weight* desde el input de cada capa hasta las capas restantes. Existe una relación directa entre la capa de entrada y la de salida además de la relación indirecta a través de las capas ocultas [23]. En este método, al igual que en el *feed forward*, la información fluye a través de las capas de forma unidireccional, como se ve en la Figura 24. Estas nuevas conexiones mejoran la velocidad y capacidad de aprendizaje de la red neuronal. Este método se adapta a la relación no lineal entre los inputs y outputs al no eliminar su relación lineal [24].

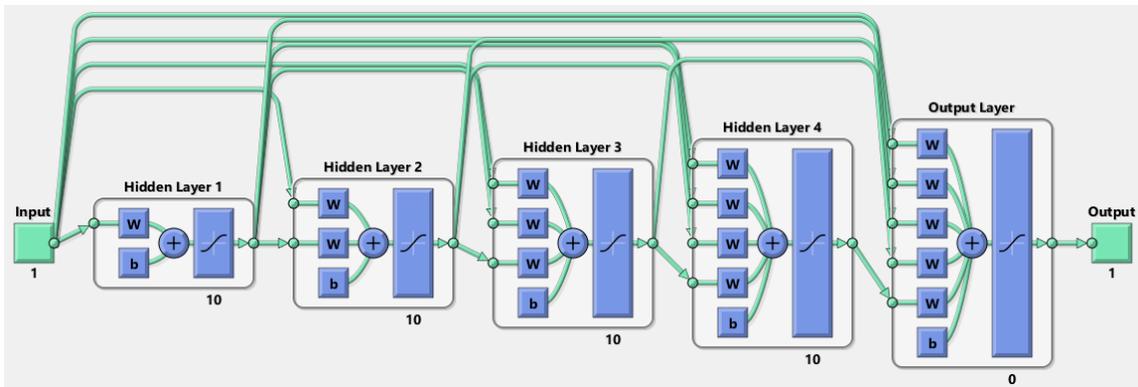


Figura 24. Estructura de la red cascade forward backpropagation en Matlab®

2.5.5.3. Proceso de aprendizaje de las Redes Neuronales

En el caso de predicción de valores mediante *Supervised Learning*, es decir, conociendo el conjunto de inputs y outputs, se afina y entrena la red hasta conseguir que el output proporcionado por la red neuronal sea lo más certero posible. Para aumentar la precisión se modifican los parámetros internos de la red neuronal, como son los *weights* y los *bias*. La precisión de la predicción se mejora comparando el valor estimado obtenido con el valor real para ir reduciendo el error a medida que se itera la calibración de dicha red neuronal.

Para realizar la primera iteración se requieren unos parámetros iniciales que se eligen de forma aleatoria. Seguidamente se computan los inputs a través de las diferentes capas. En este proceso los inputs se multiplican por su correspondiente *weight* y se les suma su *bias*. Al valor obtenido se le aplica la función de activación y esta da el output que se envía a la siguiente capa. El proceso se repite hasta alcanzar la capa de salida (*forward propagation*).

Una vez realizada la primera iteración se calcula el error y, con este, se comparan los valores obtenidos mediante la red neuronal con los valores reales. Posteriormente se modifican los valores de los *weights* y los *bias* y se repite el proceso (*backward propagation*). Este proceso iterativo se repite hasta lograr un valor del error que esté dentro de las tolerancias.

En el entrenamiento hay varios parámetros que influyen en la precisión de la red neuronal, como los mostrados en la Figura 25, que el programador de la ANN debe determinar [8]:

- *Epochs*. Estos son el número de iteraciones de tipo *forward propagation* que usa la ANN durante el entrenamiento. A medida que aumentan los *epochs* generalmente mejora la precisión de la red neuronal, a la vez que el tiempo computacional, pero llega un punto en que la mejoría aportada en precisión no compensa el aumento de tiempo computacional por lo que se pueden limitar según el caso.
- Tiempo. El tiempo computacional puede llegar a ser un problema en casos en que se disponga de una fecha límite por lo que a veces se necesita limitar el tiempo de entrenamiento de la red. Generalmente se mantiene en infinito y se busca acortar este tiempo mediante los otros parámetros.
- *Goal*. Aunque en la gran mayoría de casos el *goal* sea que el error sea 0, este parámetro también puede ser regulado para casos específicos en que el objetivo sea distinto.
- Gradiente mínimo. Debido a que a veces es imposible conseguir un error 0, se suele marcar un gradiente mínimo para el cual se considera que las mejorías aportadas no compensan el tiempo de computación por lo que se para el entrenamiento.
- *Learning rate*. Es el valor que define la variación de los *weights* y *bias* en cada *epoch*. Este valor puede ser fijo o variable según el error obtenido.
- *Momentum*. El algoritmo de entrenamiento puede estancarse en mínimos locales que hagan que la red crea que ha llegado a su error mínimo por lo que se requiere el factor *momentum* para evitar estancamientos.
- *Mu*. Es el parámetro de control para el algoritmo usado para entrenar la red neuronal. Aproxima el valor de la inversa de la matriz Hessiana. La elección de su valor afecta directamente al error de convergencia.

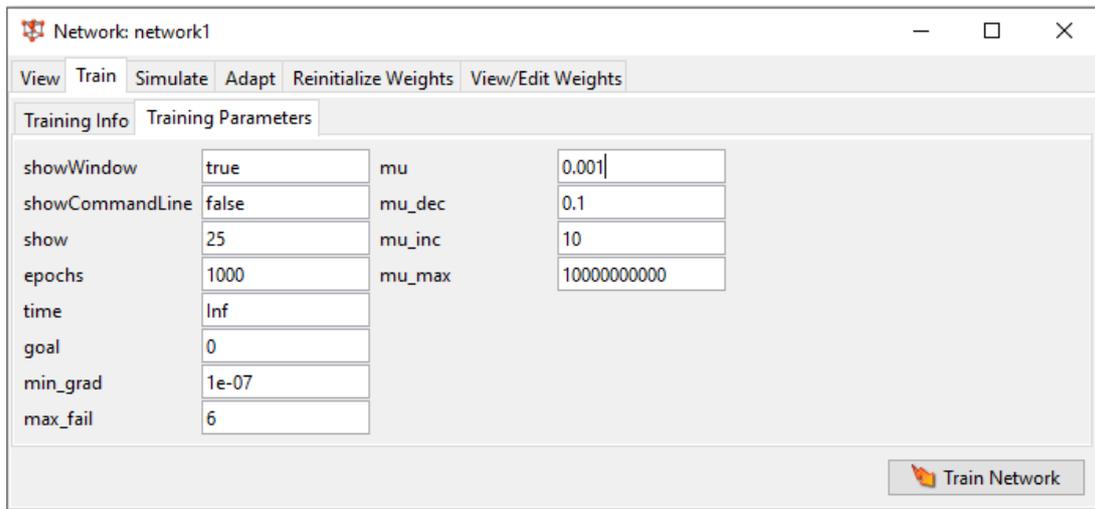


Figura 25. Ventana de elección de parámetros de entrenamiento en Matlab®

2.5.5.4. Funciones de entrenamiento

Para proceder con el aprendizaje de la red neuronal es necesario definir qué función de entrenamiento se adapta mejor al conjunto de datos. Estas funciones son algoritmos dedicados al ajuste de curvas que se aplican para poder predecir correctamente cómo evolucionan los datos.

2.5.5.4.1. Levenberg-Marquardt (LM)

El algoritmo de *Levenberg-Marquardt*, también conocido como el método de mínimos cuadrados amortiguados, se usa para resolver problemas de mínimos cuadrados no lineales. El método resulta de la combinación del descenso de gradiente y el Gauss-Newton. Es un método iterativo que, en cada iteración, según el valor de un parámetro algorítmico (λ), decide si proceder con el descenso de gradiente o el Gauss-Newton. En caso de que λ sea grande se realizará el método de descenso de gradiente. Una vez el parámetro λ sea bajo se cambiará al método Gauss-Newton. Estos cambios se realizan para poder agilizar el proceso y aumentar considerablemente la velocidad de cálculo. A medida que se acerca al error mínimo se cambia de método para aumentar la precisión. Esto lo hace mucho más veloz y preciso que usar cualquiera de los dos métodos individualmente. El método es veloz cuando se usan menos de 10 parámetros, en caso de que se usen más puede llegar a converger muy lentamente [25].

2.5.5.4.2. Bayesian-Regularization (BR)

Este método de entrenamiento actualiza los valores de *weights* y *bias* según la optimización de Levenberg-Marquardt minimizando así la combinación de errores al cuadrado y *weights*. Posteriormente determina la combinación correcta para producir una red que generalice bien.

Se diferencia del entrenamiento de Levenberg-Marquardt en su alta capacidad para revelar potenciales relaciones complejas por lo que genera un modelo más robusto [26].

2.5.5.4.3. Resilient backpropagation (RProp)

Este algoritmo usa el *supervised learning* para que, mediante el valor final deseado, adaptar y calibrar los *bias* y *weights*. Este método se diferencia de los demás en que cada *weight* y *bias* tiene su propia tasa de aprendizaje variable. Cada peso tiene un valor delta que aumenta cuando el gradiente no cambia de signo para agilizar el proceso y disminuye cuando el gradiente cambia de signo, para aportar una mayor precisión. Este algoritmo destaca por su alta velocidad de computación aún con múltiples parámetros [27].

2.5.5.4.3. Scaled conjugate Gradient (SCG)

El SCG es un algoritmo basado en direcciones conjugadas que no busca líneas en cada iteración como otros algoritmos de gradiente. Este algoritmo está diseñado para evitar perder tiempo en la búsqueda de dichas líneas para ahorrar en coste computacional. Este algoritmo aporta una alta robustez debido al uso de funciones cuadráticas de aproximación del error que las hace independientes de los parámetros definidos por el usuario.

3. METODOLOGIA

Como se ha visto en el capítulo anterior, para poder cubrir *grid codes* referentes a la potencia activa existe una alternativa a los ESS que podría llegar a suponer un abaratamiento de la inversión económica inicial. El estudio de esta alternativa es de alto interés para poder optimizar las plantas fotovoltaicas que se vean afectadas regularmente por la inestabilidad meteorológica. En el siguiente capítulo se desarrolla un sistema que permita aportar más potencia activa que la nominal o poder disminuirla considerablemente.

3.1. Método utilizado

Para poder cubrir las necesidades de los *grid codes* referidas a la potencia activa es necesario que la planta sea capaz de aportar un porcentaje de su potencia nominal extra o reducir su potencia nominal. La alternativa propuesta es trabajar con una potencia nominal inferior a la potencia disponible para así evitar recurrir al uso de ESS.

Esta alternativa se aplica mediante la mezcla del control centralizado y control distribuido. Más concretamente, los inversores siguen su referencia de potencia local y el PCC actúa para toda la planta. Es el PCC quién recibe la potencia consigna del TSO y emite las órdenes pertinentes. En este caso el PCC es el encargado de aplicar una reducción porcentual de la potencia disponible para así permitir que la potencia nominal se pueda ver aumentada. En este caso se trabajará a un 90% de la potencia disponible para ser capaz de aumentar un 10% [7] esta potencia. De esta manera se soluciona la problemática generada por uno de los principales *grid codes* que afectan a la potencia activa, el control de la frecuencia para el *under-frequency*. También es necesario cubrir la necesidad de poder disminuir la potencia hasta un 90% de la potencia disponible para cuando se produzca el *power curtailment* o el control de frecuencia para el *over-frequency*. En este caso simplemente la planta ha de ser capaz de reducir la producción máxima mediante la regulación con el PCC.

La problemática, en este caso, es la determinación de la potencia disponible para la correcta reducción para conocer a qué potencia nominal trabajar.

Para ello se recurre al uso de redes neuronales. Más concretamente, se usan inversores dedicados trabajando a su máximo potencial para poder predecir con sus lecturas el valor de la potencia disponible total de la planta. Para obtener una gran precisión hay que ubicar estos inversores de la forma óptima. En este caso se parte de la hipótesis de que la mejor opción es distribuirlos de manera homogénea por la planta. Para asegurar que la planta es capaz de reducir su potencia hasta un 10% de su potencia disponible, se toma la decisión de usar un 10% de inversores dedicados. De esta manera, en el caso extremo en que se exija reducir hasta el 10% se podrá lograr haciendo que los demás inversores estén apagados. También habrá que considerar que este 10% de inversores no será capaz de subir el 10% de potencia requerido en caso de necesidad de inyectar más potencia. Para solventar esta problemática los inversores no dedicados trabajarán a una potencia nominal del 88,88% de la potencia disponible. Una vez decidido qué inversores serán dedicados, se busca la red neuronal óptima y se entrena. Finalmente, solo queda simular dicha red para obtener el valor estimado de potencia disponible de la planta y así enviar esta consigna al PCC para que este pueda actuar de forma consecuente.

3.2. Proceso de estimación de la red neuronal

Para la creación y entrenamiento de la red neuronal se siguen una serie de pasos que permiten elegir la red que aportará una mayor precisión y menor tiempo computacional.

3.2.1 Pretratamiento de datos

En el caso de predicción y estimación de valores, como es el de este trabajo, la veracidad y calidad de los datos que se introducen para entrenar la inteligencia artificial son un aspecto muy importante del que dependerá la precisión y calidad de predicción. Por ello se requieren valores correctos y limpios de posibles alteraciones que puedan malmeter dicha veracidad. En este caso se trabaja con valores de potencia entregada de los inversores de una planta fotovoltaica para varios días de funcionamiento. La planta no trabaja mediante el método del presente trabajo, sino que todos los inversores trabajan a MPP, por lo que si no se produce ningún recorte debido a grid codes, la potencia entregada es igual a la potencia disponible.

Inicialmente, mediante el software Microsoft Excel®, se ordenan los datos de forma cronológica para así realizar una mejor lectura de estos. Seguidamente se analizan para ver de forma general aquellos posibles errores que se puedan solucionar fácilmente como podrían ser los valores negativos, que se dan por errores al estimar valores muy cercanos al cero, por lo que se sustituyen por 0.

A continuación, se analizan los inversores individualmente para ver si alguno no ha tomado medidas correctas, ya sea porque no ha tomado ninguna medida y todos sus valores son 0 o porque ha habido algún problema por el cual el valor dado es constante e igual al último valor registrado, por lo que ese valor es erróneo. Estas columnas de inversores con errores han de ser eliminadas y no deben ser usadas.

Seguidamente se tiene que uniformizar el conjunto de datos asegurando el mismo número de filas y columnas en los distintos vectores de datos correspondientes a las mismas variables durante los diferentes periodos de tiempo. En el caso en que un inversor dé valores nulos en un solo día, debe ser eliminado de todos los días para asegurar que se parte del mismo número de datos para cada día.

Para poder proceder de forma correcta se requieren los valores de potencia disponible de los inversores, pero la base de datos es de potencias entregadas. En caso de que no se produzca *power curtailment*, se puede aproximar el valor de la potencia disponible con el valor de la potencia entregada, negligiendo las pérdidas. En el caso de que, por algún motivo, el *setpoint* de los inversores esté por debajo del valor de la potencia nominal, se produce *power curtailment*. En ese caso, el orden de potencia activa emitida por el PCC a los inversores dejará de ser el valor máximo, reduciéndose hasta el valor en el que se produce el *power curtailment*, por lo que podemos identificar aquellos valores que no están trabajando a MPP evaluando si su potencia entregada es ligeramente menor o mayor que el orden de potencia activa, en cuyo caso sí se produciría *curtailment*, o si es considerablemente menor, en cuyo caso no se produciría. Para ello, se considera que aquellos valores que estén trabajando por encima del 95% del valor de su orden de potencia activa están trabajando bajo *power curtailment*. Estos valores se deben eliminar, pero al eliminarlos se pierde la continuidad de los datos recogidos por lo que se realiza una interpolación para estimar el comportamiento de la potencia disponible

durante los tramos eliminados. De esta forma sabemos que habrá error, pero será mucho menor que si no tuviéramos en cuenta estos datos o si no tuviéramos en cuenta el efecto del *power curtailment*.

3.2.2 Redes neuronales

Una vez tratados los datos de potencia disponible se procede a analizar qué tipo de red neuronal se adecua más a los datos y al caso. En este caso nos centramos en la analítica predictiva de datos. Concretamente interesa hacer una predicción a corto plazo para saber en todo momento la potencia disponible a partir de un número determinado de inversores que trabajen a MPP.

En el caso que nos concierne se parte de una serie temporal de datos de 7 días que nos proporciona el valor deseado de la predicción, es decir, el valor de la potencia disponible, por lo que se usará el enfoque de *Supervised Learning*. De las diversas ramas del *Machine Learning*, la que más se adapta al caso es el *Deep Learning* por lo que se partirá de este. Esta decisión se toma basándose en la gran cantidad de datos disponibles con los que entrenar la red. Habiendo en total 46.216.800 datos con los que trabajar podemos asegurar un buen entrenamiento mediante *Deep Learning* y una buena precisión.

Debido a que los datos de los que partimos son de naturaleza *time series data* la estructura de red neuronal de mayor interés es la recurrente. Este tipo de estructura contiene conexiones entre nodos a lo largo de secuencias temporales por lo que, mediante una memoria interna, permite recordar los inputs. Consecuentemente, permite realizar un más profundo reconocimiento de las secuencias comparado con otras estructuras de redes neuronales y así lograr que la red sea muy precisa a la hora de realizar predicciones de los siguientes valores.

La red neuronal creada se entrenará y simulará mediante el uso de las potencias de los inversores dedicados como inputs. Dicha red devolverá como output la estimación de la suma de potencias de la planta. Para la elección de la función de activación se analizarán todas las posibles funciones no lineales para valorar cuál aporta una mayor precisión. Descartamos las funciones de activación lineales debido a su baja precisión en comparación con las no lineales.

Esta red neuronal contará con diversas capas ocultas a determinar mediante ensayos experimentales, comprendidas todas por el mismo número de neuronas, también a determinar mediante ensayos. En este caso es importante evitar el *overfitting*; que es el sobreentrenamiento de los datos producido cuando hay un gran número de capas y neuronas, y el *underfitting*; el cual sucede cuando hay un bajo número de capas y neuronas y suele derivar en una falta de capacidad de detección de patrones [28]. Se descarta analizar redes neuronales con distintos números de neuronas en sus diferentes capas ocultas debido al tiempo computacional que supondría simular cada caso para elegir el mejor. Consideramos que la mejoría en precisión que podría llegar a aportar no compensa el aumento exponencial de tiempo y capacidad computacionales que supondría.

Para comprobar que la red neuronal es precisa y correcta se requiere una simulación posterior al entrenamiento con datos con los que la red no se haya entrenado.

Primeramente, se realizará una simulación con la mitad de los inversores trabajando a MPP para tener una primera idea de la precisión de la red. Esta simulación no aportará más que un leve control del buen funcionamiento de la red neuronal debido a que no servirá para su aplicación

real debido a que en ese caso solo se podría reducir la potencia entregada hasta el 50% de la potencia disponible de la red.

Posteriormente, se realizará otra simulación con el 10% de los inversores trabajando a MPP para ver si la precisión disminuye hasta valores en que deje de ser útil la red neuronal. Este caso es el de mayor interés debido a que, como se menciona anteriormente, permite reducir la potencia entregada hasta un 10% de la potencia disponible. Al tener solo un 10% de inversores dedicados se tendrán que localizar estratégicamente para abarcar el máximo área posible y así aportar una mayor precisión.

Una vez validado el modelo se procederá a simular cómo sería la predicción en el caso en que se aplicara el método NREL para así, posteriormente, poder compararlo con el uso de redes neuronales y valorar si la mejoría de precisión es suficientemente notable. En este caso se tomarán también un 10% de inversores trabajando a MPP localizados de la misma manera que en el caso anterior. Se considerará que la potencia disponible de los inversores de las zonas de control virtual es la misma que la del inversor dedicado de dicha zona.

4. Aplicación de la metodología

Una vez determinada la metodología a seguir se procede a aplicarla a los datos cedidos. Este trabajo se aplica a los datos de una planta fotovoltaica real cuya información es confidencial por lo que los datos explícitos mostrados para la mejor comprensión del trabajo son falsos. Los resultados en cambio sí son de los datos reales.

4.1. Pretratamiento de datos

Inicialmente se analizan los datos sobre los cuales se trabajará para ver si hay alguna limitación debido a la falta de datos.

4.1.1. Datos de partida

Se dispone de datos de 4 parámetros recogidos a lo largo de varios días con una ratio de 60 datos/minuto y un 5º parámetro derivado de operar proporcionalmente uno de los iniciales. Estos datos son los siguientes:

- Potencia entregada por cada inversor de la planta (P_{EI})

Se dispone de la potencia entregada por cada inversor en un día normal de trabajo (Figura 26). Esta potencia entregada puede estar afectada por *power curtailment* en determinados momentos en que lo requiere la red, por lo que los inversores no tienen por qué estar siempre trabajando a MPP y las potencias no tienen por qué ser igual a la potencia disponible. Como se necesitan los valores de la potencia disponible para entrenar y elaborar el algoritmo de predicción, posteriormente se analizará en qué momentos sucede el *power curtailment* y mediante una interpolación se generarán nuevos valores que se aproximarán al valor real que desconocemos.

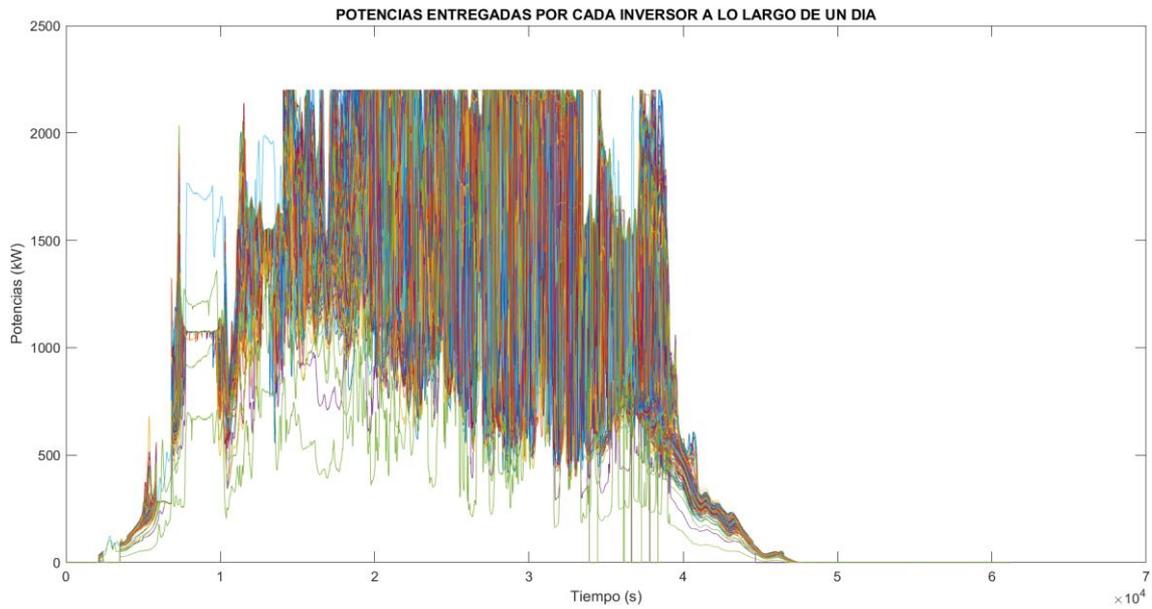


Figura 26. Potencias entregadas por cada inversor a lo largo de un día

- Potencia entregada en el PCC (P_E)

La potencia entregada en el PCC es la potencia entregada en el punto de conexión de la LS-PVPP con la red eléctrica (Figura 27). Este valor resulta de sumar las potencias individuales de cada inversor y restar las pérdidas que resultan de transportar esa energía hasta el PCC.

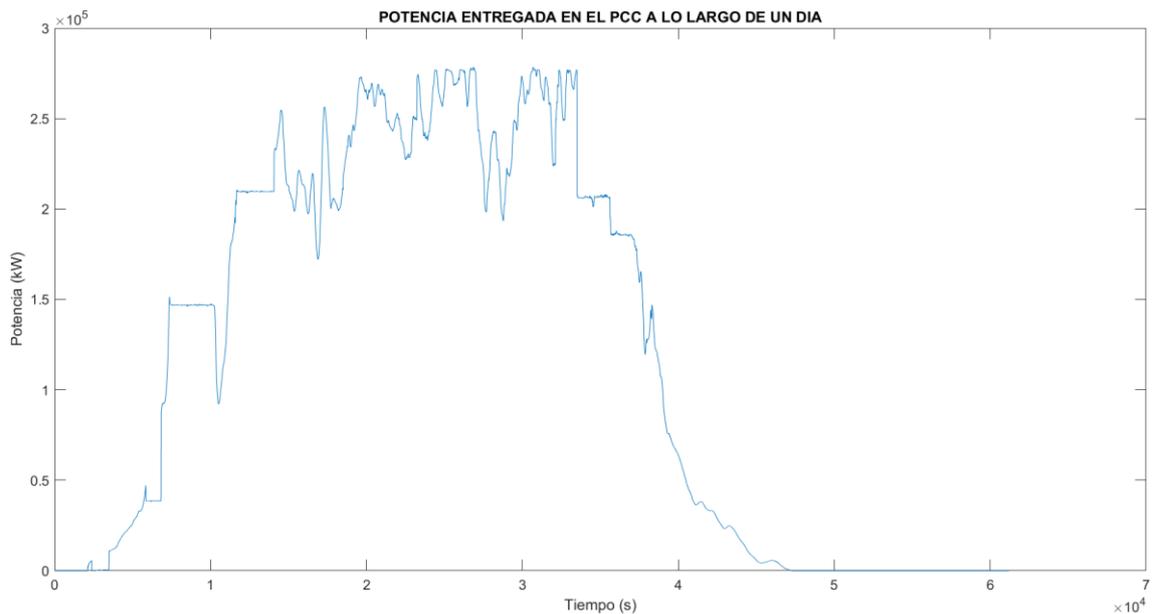


Figura 27. Potencia entregada en el PCC a lo largo de un día

- Potencia de consigna enviada por el TSO (P_{CO})

La potencia de consigna (Figura 28) es aquella que limita la potencia que inyecta la LS-PVPP a la red, por la cual se produce el *power curtailment* anteriormente mencionado.

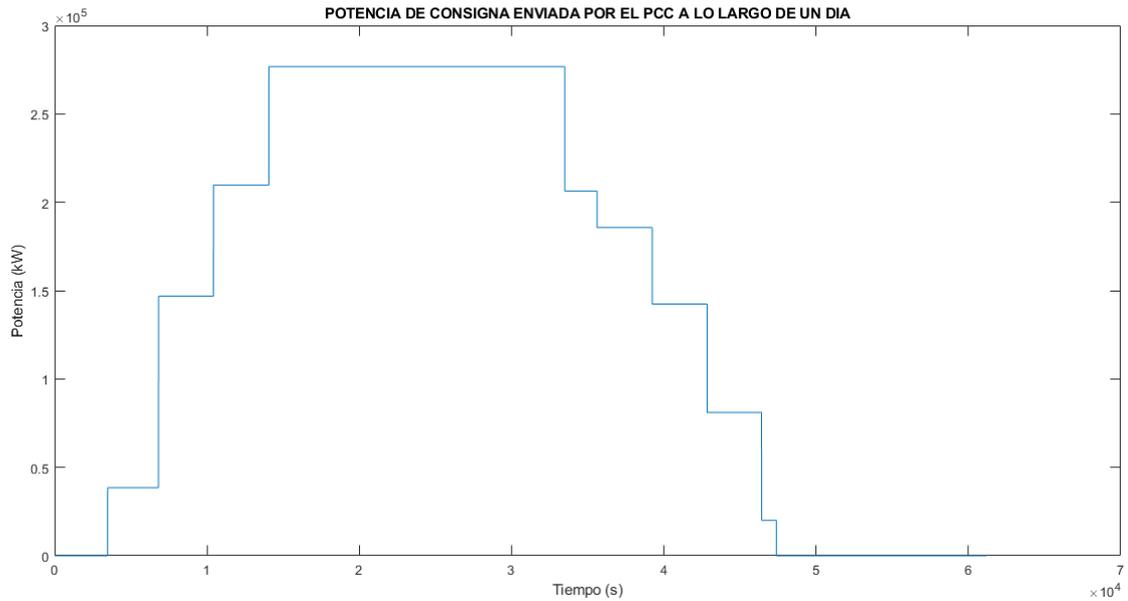


Figura 28. Potencia de consigna enviada por el PCC a lo largo de un día

- Orden de potencia activa a los inversores (P_O)

El orden de potencia (Figura 29) es la limitación puesta sobre los inversores para que la P_E no supere la P_{CO} . Gracias a este dato podremos ver en qué momentos se produce el *power curtailment* y podremos saber qué valores reemplazar mediante las interpolaciones.

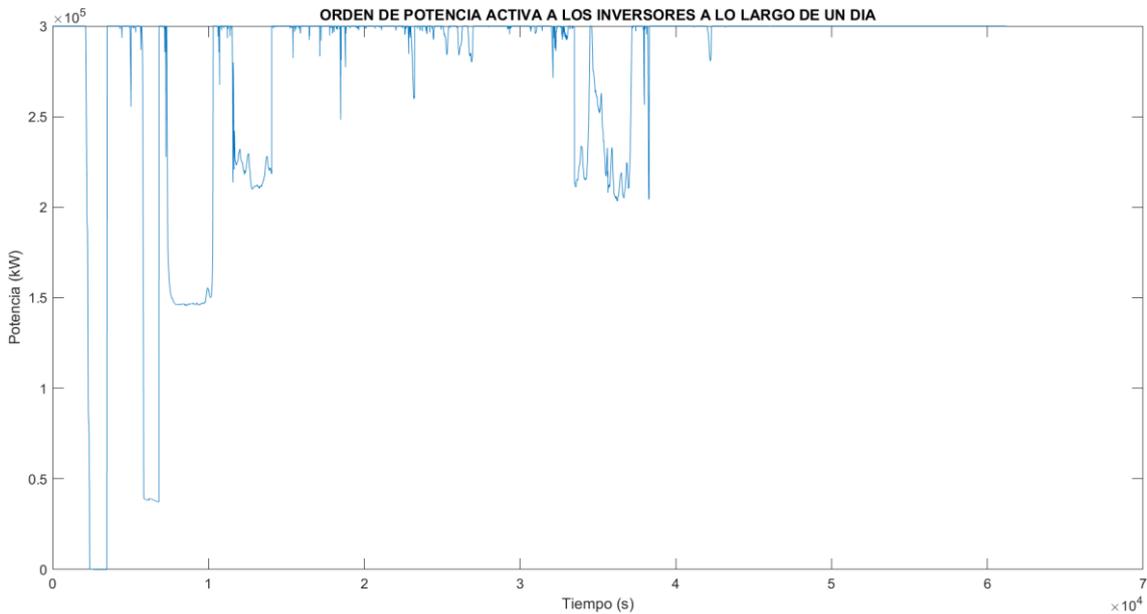


Figura 29. Orden de potencia activa a los inversores a lo largo de un día

- Orden de potencia activa individual (P_{O_i})

Para poder analizar los inversores uno a uno se calcula el orden de potencia activa a los inversores de forma individual a partir de la P_O (Figura 30). Se obtienen los valores realizando la proporción entre la potencia máxima alcanzable por la planta y cada inversor de forma individual.

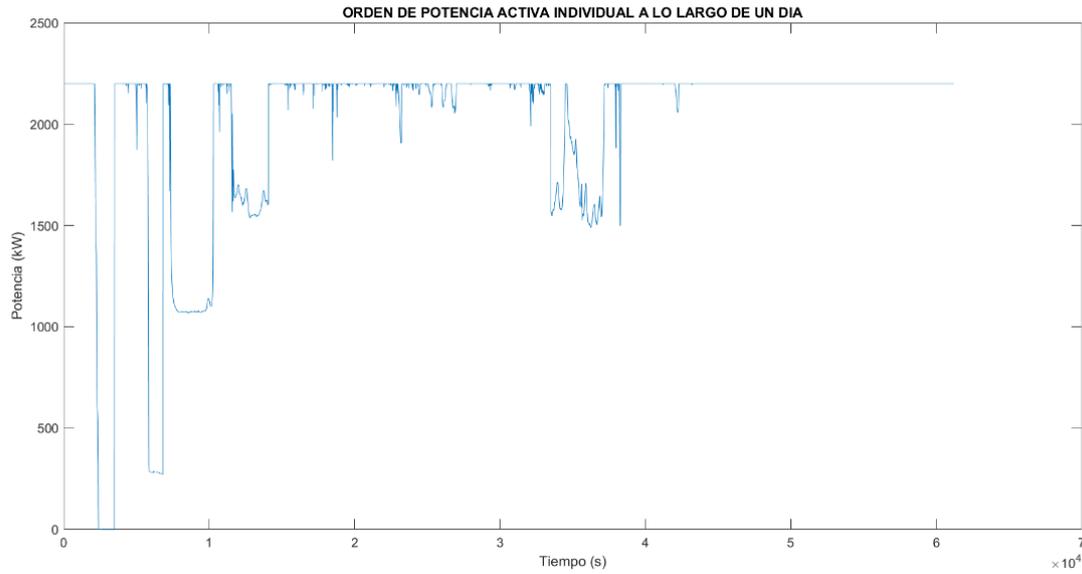


Figura 30. Orden de potencia activa individual a lo largo de un día

4.1.2. Aplicación

Para iniciar el pretratamiento de los datos (Figura 31) inicialmente comprobamos que concuerden las fechas de los datos obtenidos de los 5 parámetros iniciales (Tabla 1).

Tabla 1. Distribución de los datos según los días y la disponibilidad

	19/06	20/06	21/06	22/06	23/06	24/06	25/06	26/06	27/06
P _{EI}	✓	✗	✓	✓	✓	✓	✓	✓	✓
P _E	✓	✓	✓	✗	✓	✓	✓	✓	✓
P _{CO}	✓	✓	✓	✓	✓	✓	✓	✓	✓
P _O y P _{OI}	✓	✓	✓	✓	✓	✓	✓	✓	✓

Para seguir con el tratamiento de los datos es necesario que en los días analizados haya datos de todos los parámetros. En caso de que haya días en que falten todos los datos de un parámetro, estos días no podrán ser considerados a la hora de entrenar la red. Por ende, los días de los cuales se conoce toda la información necesaria y que serán usados para entrenar la red son los siguientes: 19/06/2020, 21/06/2020, 23/06/2020, 24/06/2020, 25/06/2020, 26/06/2020 y 27/06/2020.

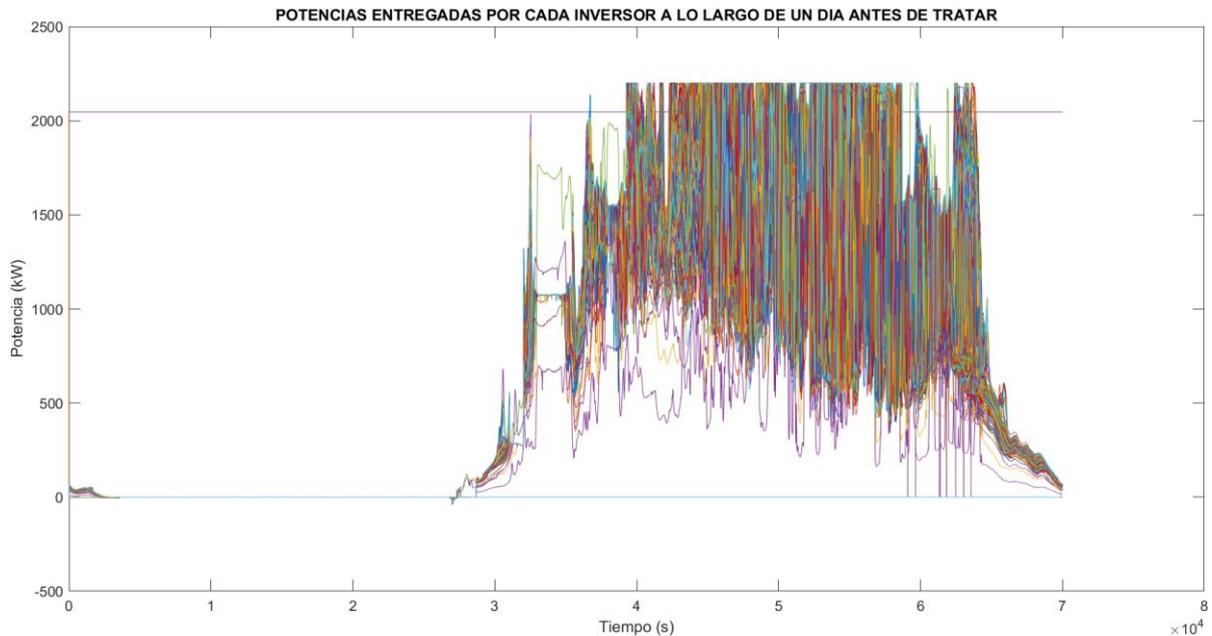


Figura 31. Potencias entregadas por cada inversor a lo largo de un día antes de tratar

Para facilitar el tratamiento de datos, estos se analizarán y tratarán de forma diaria. Inicialmente se ordenan los datos de forma cronológica. Como hay inversores con más datos que otros, elegimos un rango horario a analizar que abarque todas las horas de sol del día. Por ello, se estudiará el rango horario de 7am-9pm.

Una vez ordenados los datos, buscamos los valores anómalos que pueda haber. Primeramente, vemos que existen diversos valores negativos debido a errores de precisión. Estos no pueden ser reales debido a que la potencia producida por un inversor no puede ser nunca negativa, por lo que mediante Matlab® sustituimos todos los valores negativos de potencia por valores nulos.

Además, también puede haber inversores con comportamiento anómalo, ya sea porque están apagados y todos sus valores son nulos, como en el caso de los inversores 3.1, 3.2, 6.1, 6.2, 10.1, 10.2, 20.1, 20.2, 25.1, 25.2, 35.1, 47.1, 54.1 y 54.2, o porque por algún error dan siempre un valor constante, como en el caso del inversor 43.2. Estos valores se eliminan.

Una vez eliminados y/o corregidos los valores anómalos, consideramos que ya tenemos una base de datos sólida sobre la cual podemos trabajar sin influencia de dichos valores.

Como se menciona anteriormente, para entrenar la red se necesita conocer el valor de los inversores trabajando en el MPPT, es decir, se necesita tratar las P_{Ei} para obtener así los perfiles de potencias fotovoltaicas disponibles (P_{DISP}). Para ello, mediante Matlab®, se ha creado una función que, dados los valores de potencia entregada y los del P_{Oi} , devuelve el valor de la P_{DISP} habiendo interpolado aquellos valores que desconocemos.

Primeramente, hace falta saber qué valores están afectados por el *power curtailment*, es decir, qué valores habrá que sustituir. Para ello, partimos del P_{Oi} , que marca las limitaciones que pueden sufrir los inversores de forma individual. En caso de que se deba limitar la potencia entregada, el valor del P_{Oi} está por debajo del máximo (2200 kW) y la potencia disponible baja hasta estabilizarse ligeramente por debajo del P_{Oi} . Debido a la gran cantidad de datos, primeramente, se considera que siempre que el P_{Oi} sea el máximo, los valores de la P_E son iguales a los valores de P_{DISP} , por lo que esos datos no se tendrán que tratar. Como puede darse el caso

de que haya un P_{OI} menor que el máximo pero que no fuerce *power curtailment*, hay que filtrar estos casos. Para ello, evaluamos si el valor de P_E mayor que $0,95 * P_{OI}$. De esta manera conocemos aquellos valores que habrá que interpolar posteriormente (Figura 32). Estos valores al ser erróneos hay que eliminarlos, dando lugar a los huecos que habrá que interpolar posteriormente.

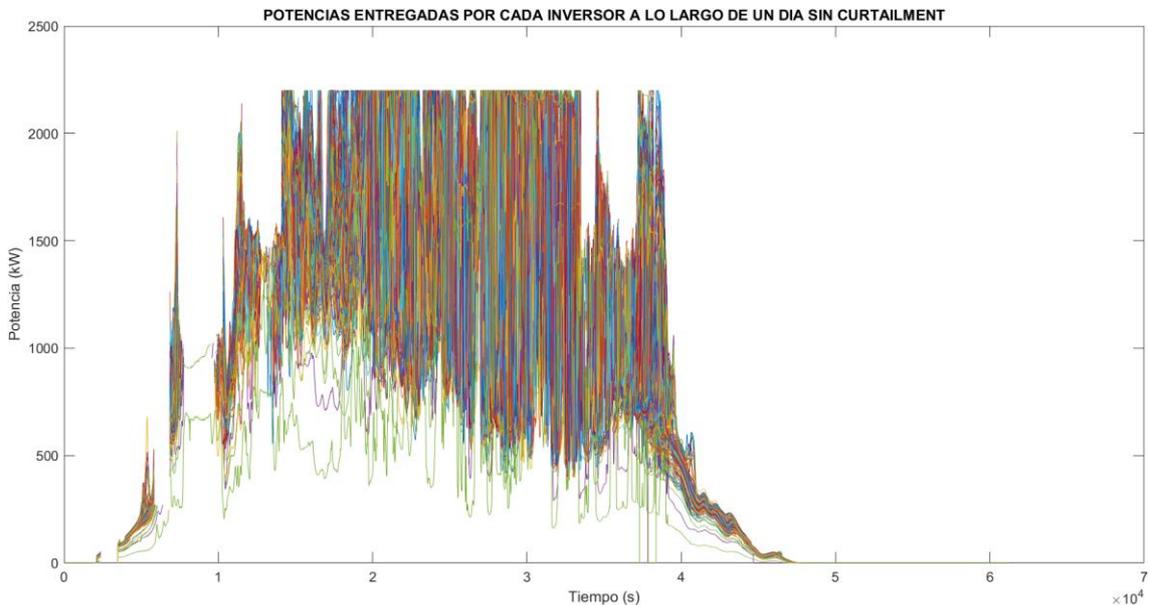


Figura 32. Potencias entregadas por cada inversor a lo largo de un día sin curtailment

A la hora de interpolar se elige la interpolación 1-D debido a que cada inversor actúa de forma individual sin tener que depender directamente del siguiente inversor.

Para obtener la mejor precisión de interpolación posible se analizan diversos métodos para ver cuál aporta un resultado más cercano a la realidad.

Los métodos más comunes son *previous*, *linear*, *pchip* y *spline*. Debido a la naturaleza de los datos se considera que los métodos *previous* y *linear* no aportan la precisión requerida por la problemática presentada. Para elegir entre *pchip* y *spline* analizamos el resultado que nos da cada método para así ver cuál se adapta mejor al modelo.

- *Spline*

Primeramente, analizamos el caso de la interpolación mediante *spline*. Para ello graficamos las potencias individuales de cada inversor y la suma de dichas potencias junto con la potencia disponible para ver si el resultado es lógico.

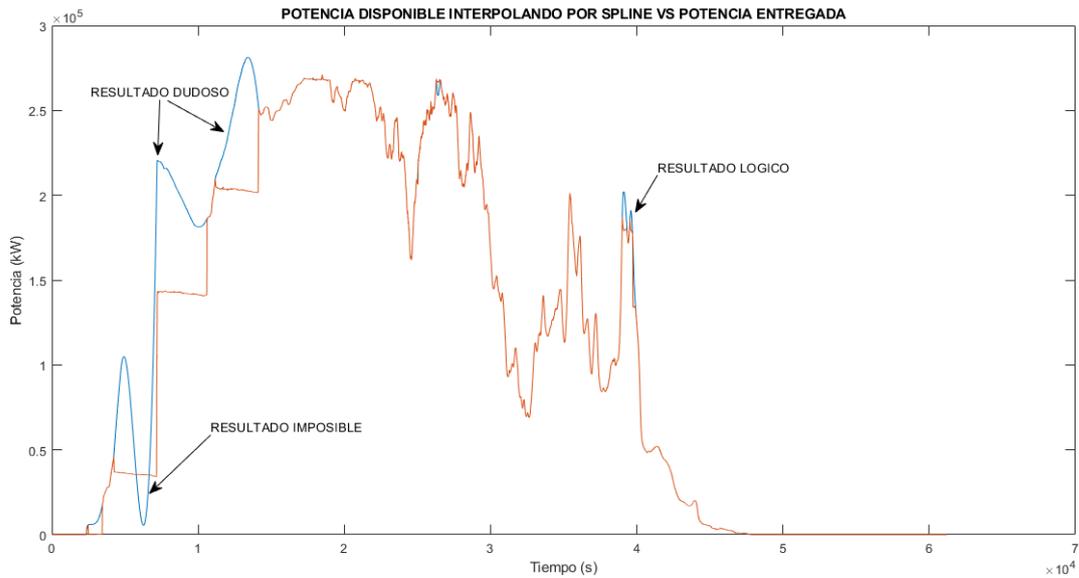


Figura 33. Potencia disponible interpolando por spline Vs P_E

En la Figura 33 se aprecia que la interpolación mediante *spline* da un resultado lógico y bueno en determinados tramos, pero en otros da valores de dudosa veracidad debido al pico inicial que toma valores muy elevados que podrían llegar a ser reales, pero no habituales. También hay tramos en que el valor interpolado es inferior al entregado, cosa que es imposible en la realidad debido a que, el único caso en que el valor entregado es distinto al disponible es en el que debido al *power curtailment*, es inferior a este.

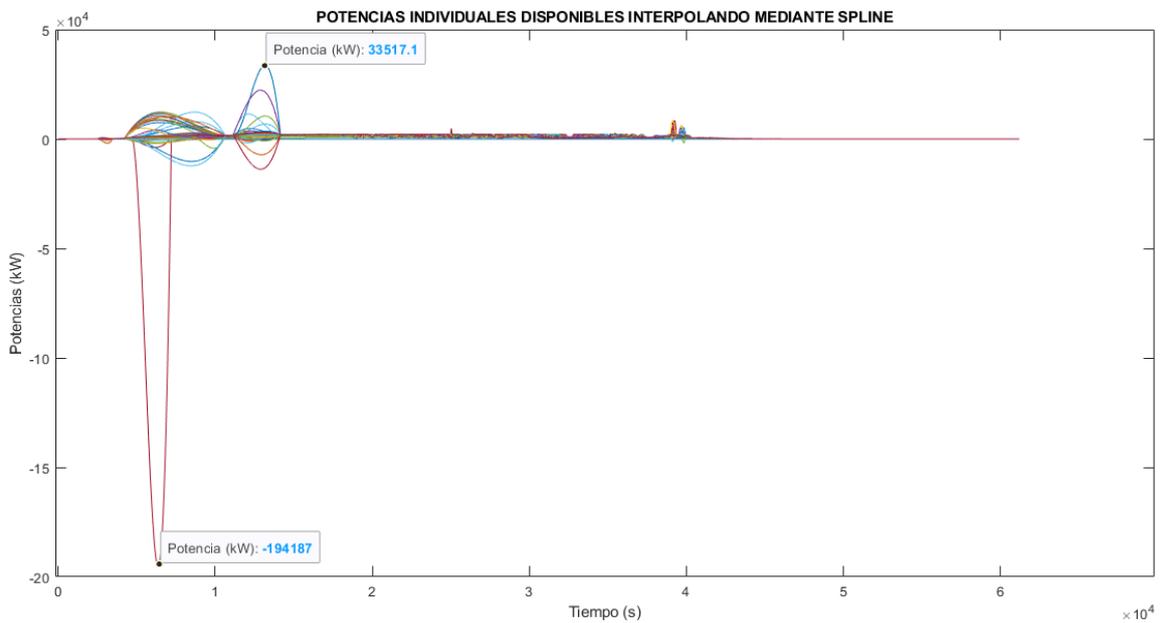


Figura 34. Potencias individuales disponibles interpolando mediante spline

Al analizar los valores individuales de la potencia disponible interpolada (Figura 34) vemos que hay valores que se disparan sin sentido cuyo valor no puede ser real. Hay valores negativos y valores que exceden el límite de los inversores.

- *Pchip*

Seguidamente se analizan los valores obtenidos al interpolar mediante el método *pchip*.

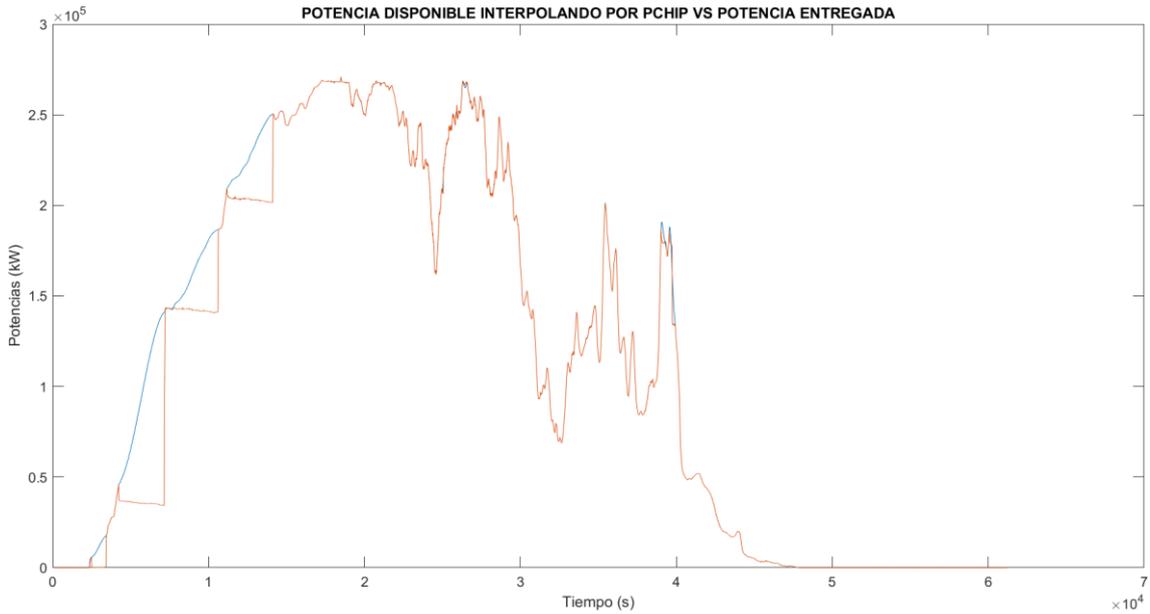


Figura 35. Potencia disponible interpolando por *pchip* Vs P_E

Como se aprecia en la Figura 35, no hay valores anómalos que indiquen que la interpolación es errónea. Los valores parecen lógicos por lo que procedemos a analizar los inversores individualmente para confirmar que el método es el más preciso.

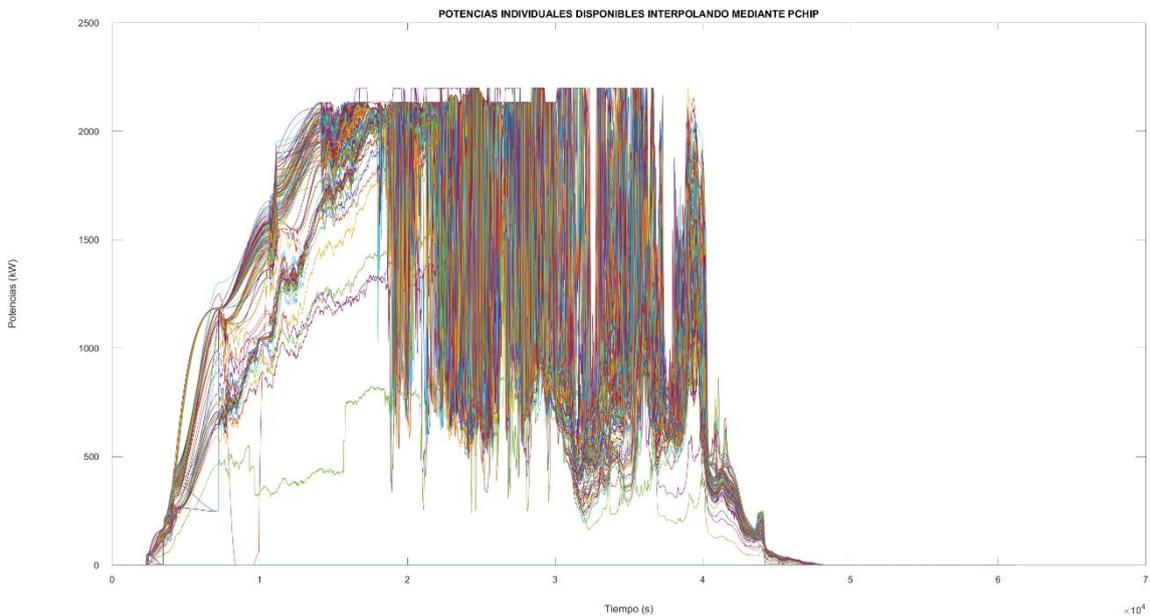


Figura 36. Potencias individuales disponibles interpolando mediante *pchip*

En la Figura 36 podemos apreciar que, aunque individualmente no sigan el mismo patrón inestable, no hay valores anómalos o desproporcionados.

Una vez tratados los datos iniciales para obtener los valores de la potencia disponible de la planta para los diferentes días se procede a la creación de la red neuronal.

4.2. Redes neuronales

Inicialmente se distribuyen los días en dos grupos; los que se usarán para entrenar la red neuronal y los que se usarán para validar y así corroborar la precisión de esta red neuronal.

Tabla 2. Elección de las cantidades de datos dedicadas al entreno de la red neuronal y a la simulación de esta

	21/06/20	21/06/20	21/06/20	21/06/20	21/06/20	21/06/20	21/06/20
TRAIN/SIM	TRAIN	TRAIN	TRAIN	TRAIN	TRAIN	SIM	SIM

Se utilizarán los datos de los primeros 5 días para entrenar la red neuronal. Se aportará un 5/7 de los datos a entrenar la red debido a la gran importancia que tiene conseguir una buena precisión en esta. Únicamente los 2 últimos días serán destinados a la simulación y verificación de la red neuronal para así poder analizar los errores de dos días distintos y reducir la posibilidad de error a la hora de comprobar la veracidad y precisión de la red neuronal (Tabla 2).

4.2.1. Elección del programa y creación de la red

Dentro de las múltiples posibilidades a la hora de crear y trabajar con redes neuronales se ha elegido la herramienta *nntool* de Matlab®, Figura 37. Esta herramienta es muy intuitiva y permite importar, crear, usar y exportar redes neuronales y datos. Su principal desventaja es el alto coste de la licencia de Matlab®. Al realizar el presente trabajo siendo estudiante de la UPC puedo contar con dicha licencia de manera gratuita.

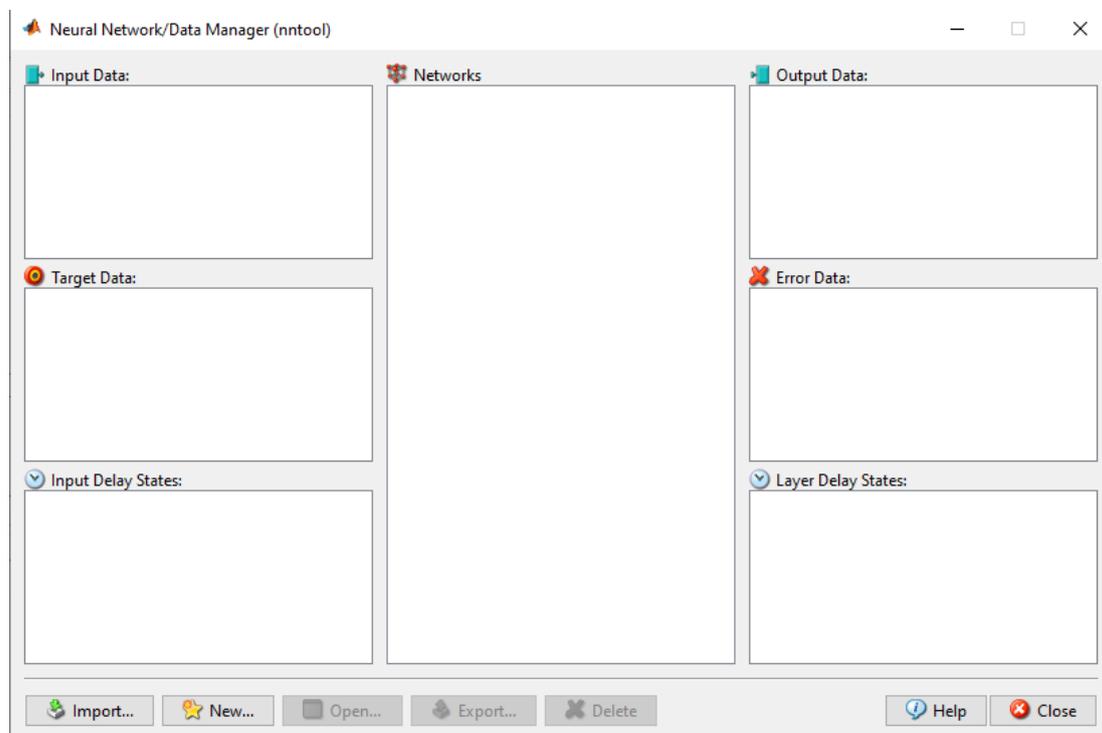


Figura 37. Interfaz de la herramienta *nntool*

La complejidad de la herramienta reside en la elección de los parámetros de la red neuronal, mostrados en la Figura 38, y su creación. Para obtener la mejor red neuronal para el proyecto se ha considerado realizar múltiples análisis partiendo de una cantidad de datos de entrada baja para agilizar el proceso. Se realizará la selección de parámetros mediante el entrenamiento de las diversas opciones y alternativas para cada parámetro. Debido al alto tiempo computacional que supondría realizar dichos cálculos con todos los datos se recorta la cantidad de datos considerando que, al realizar dicho recorte a todas las alternativas, estas se verán afectadas por igual y su comparación no se verá afectada significativamente. El input data que se usará para entrenar la red serán 705.600 datos correspondientes a las potencias disponibles de 14 inversores en el primer día. Para poder entrenar correctamente la red se requerirá el *Target data*, que es la suma de potencias disponibles de toda la planta para todo el primer día. Estos datos son los que se usarán para poder calcular el error e ir reduciéndolo en cada iteración.

Esta reducción considerable de datos se realiza debido al alto tiempo computacional que supondría analizar tantas combinaciones con todos los datos. En caso de no tener un tiempo límite sería mejor realizar estos ensayos con todos los datos disponibles para conseguir una mayor precisión, a costa de un mucho mayor tiempo computacional.

Una vez calculadas las distintas redes se valorará su precisión. Para ello se entrenarán las redes y se comparará el valor de salida predicho con la red neuronal y el valor teórico de las sumas de potencias.

Se compararán teniendo en cuenta los siguientes parámetros:

- El error absoluto acumulado
- El error relativo medio para los instantes en que la suma de potencias sea superior a 2000 kW, para obtener un valor más realista sin ser distorsionado por los valores de suma de potencia bajos.
- El coeficiente de correlación R2

En estos análisis se valorará qué parámetros tienen una mejor sinergia para crear la red neuronal más precisa posible.

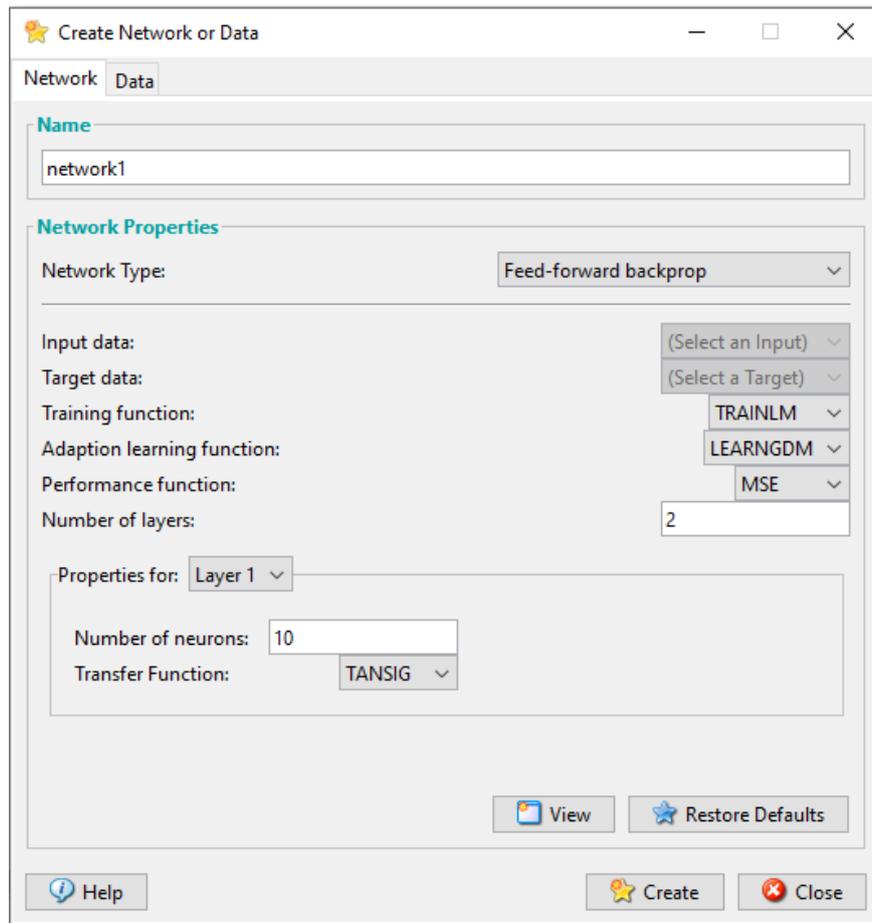


Figura 38. Interfaz de la creación de una red neuronal mediante la herramienta nntool

4.2.2. Elección de tipo de red neuronal

Primeramente, se analizan los diferentes tipos de redes neuronales dejando los demás parámetros con su opción predeterminada para todos los tipos. Los únicos parámetros que se modifican, de igual manera para todos los tipos de red neuronal, son el número de capas y de neuronas. Para conseguir una buena precisión evitando el *overfitting* y el *underfitting* elegimos un número de capas igual a 5 y un número de neuronas por capa igual a 10, a excepción de la última capa, la cual solo tiene 1 neurona. De esta manera aseguramos que haya suficientes *bias* y *weights* con los que iterar e ir calibrando la red.

Se simulan los tipos de red más usuales (Figura 39) en el caso de predicción de *time series data*, explicados en el apartado 0.

TIPOS DE REDES NEURONALES

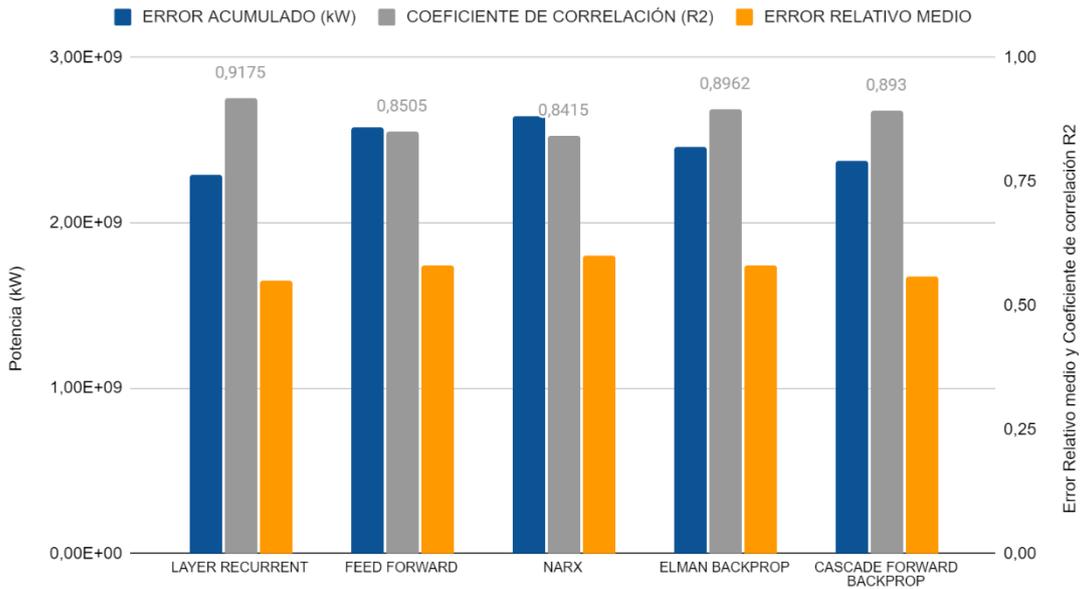


Figura 39. Comparación entre las distintas redes neuronales

Al realizar el entrenamiento de las 5 redes neuronales se aprecia cómo la que da un mayor coeficiente de correlación, a la vez que el menor error acumulado y el menor error, es la *Layer recurrent*. Previamente ya se ha visto que esta red neuronal es la que mejor se adapta a la naturaleza de los datos, pero igualmente se realiza este ensayo para corroborarlo.

4.2.3. Elección de la *training function*

Una vez elegido el tipo de red neuronal se procede a evaluar las múltiples funciones de entrenamiento disponibles en el programa para ver cuál se adecua mejor al caso. De los parámetros que aún no se han elegido no se cambia nada, siguen siendo los valores predeterminados y 4 capas de 10 neuronas por capa más 1 última capa de 1 neurona.

TIPOS DE TRAINING FUNCTIONS

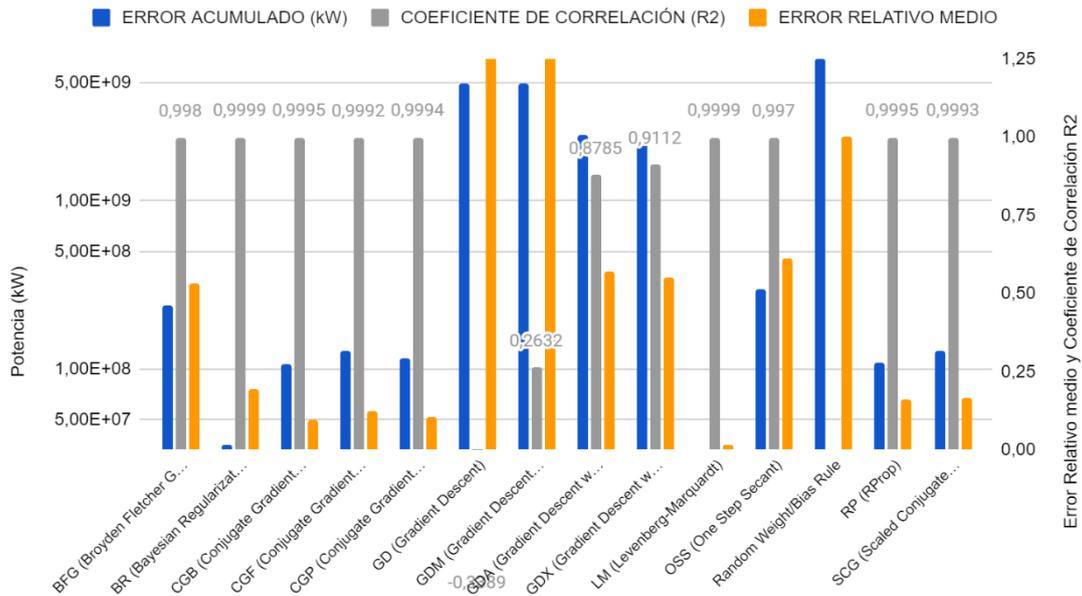


Figura 40. Comparación de los distintos tipos de training functions

Una vez realizados los entrenamientos vemos que las funciones de entrenamiento que mejores resultados dan son la LM (Levenberg-Marquardt) y la BR (Bayesian-Regularization), seguidas de la RP (Resilient backpropagation) (Figura 40). Las primeras dos se desmarcan mucho de la 3ª mejor, pero eso es a costa de aumentar un 1200 y 1300% el tiempo y la capacidad de computación. Las primeras dos tardaron 3h5min y 3h15min mientras que la tercera tarda 15min. Estos tiempos resultan de los cálculos de una red neuronal con 1/5 parte de los datos por lo que el tiempo de computación del conjunto entero de datos se elevaría a tiempos desproporcionadamente altos. Aunque las primeras dos opciones serían las mejores en un caso en que el tiempo no fuese un problema, en este caso al tener el tiempo limitado se ha decidido proceder con la tercera opción. Esta sigue dando unos valores capaces de abordar el presente trabajo con alta precisión.

4.2.4. Elección del número de capas y neuronas.

Debido a la infinita posibilidad de combinaciones de capas y neuronas y al alto tiempo y coste computacionales se decide realizar cálculos para una limitada cantidad de neuronas y de capas. Se realizan cálculos para las combinaciones de 4, 5, 6 y 7 capas con 10, 20, 30, 40, 50, 60, 70, 80, 90 y 100 neuronas.

ERROR ACUMULADO (kW)

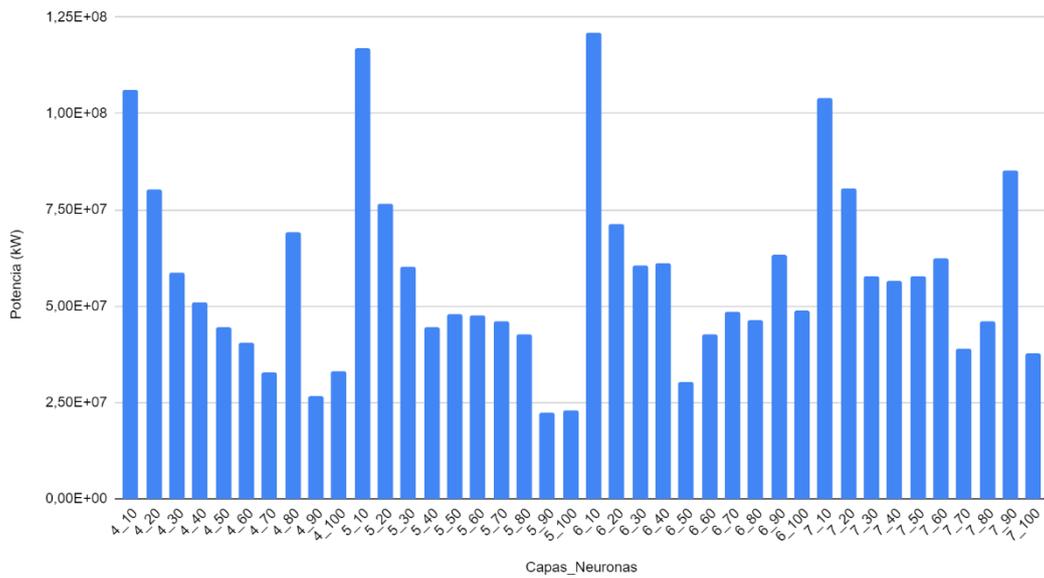


Figura 41. Comparación del Error Absoluto acumulado para las distintas combinaciones de capas y neuronas

ERROR RELATIVO MEDIO (%)

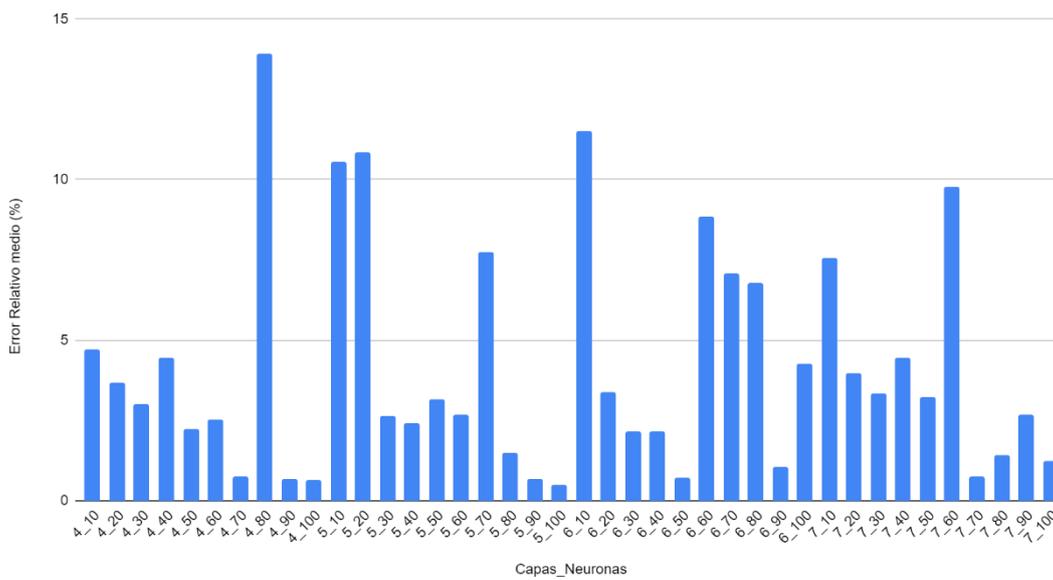


Figura 42. Comparación del Error Relativo medio para las distintas combinaciones de capas y neuronas

COEFICIENTE DE CORRELACIÓN (R2)

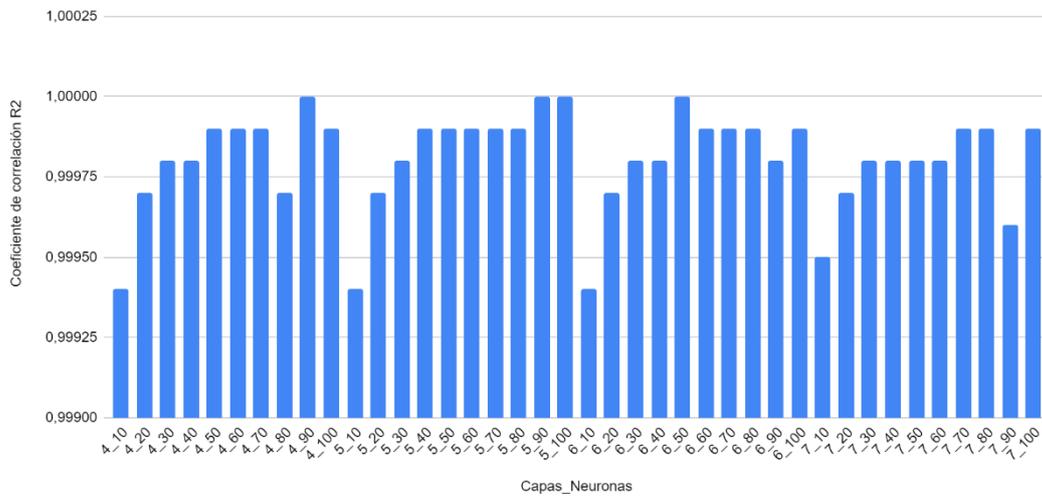


Figura 43. Comparación del Coeficiente de Correlación R2 para las distintas combinaciones de capas y neuronas

TIEMPO

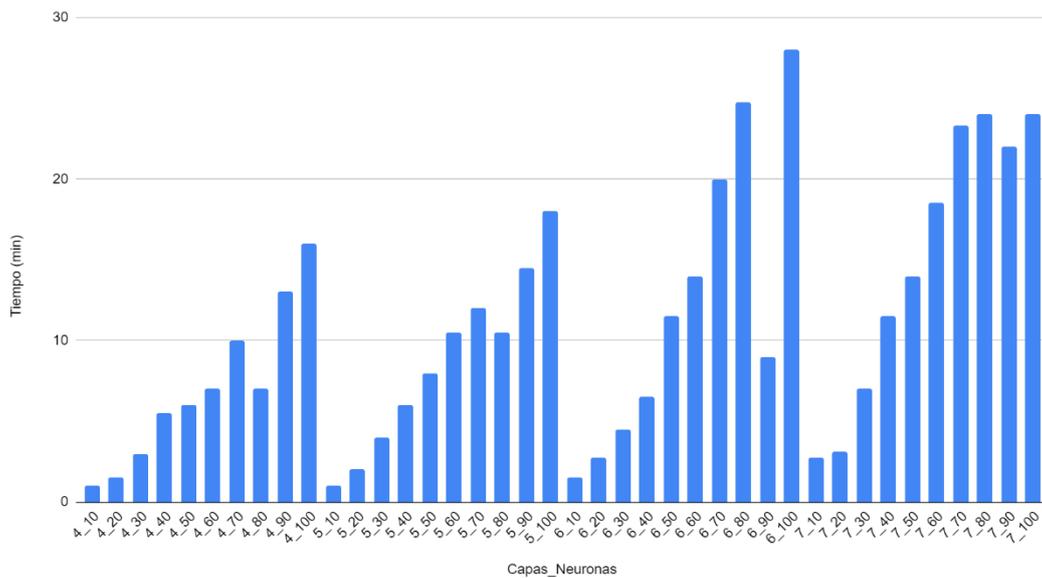


Figura 44. Comparación del Tiempo computacional para las distintas combinaciones de capas y neuronas

En este caso, al ser el aumento del tiempo de computación proporcional al aumento de capas y de neuronas, también se toma en cuenta (Figura 44)Figura 44. Comparación del Tiempo computacional para las distintas combinaciones de capas y neuronas.

La combinación que minimiza el error absoluto acumulado es la de 5 capas y 90 neuronas (Figura 41). Respecto al error relativo, la combinación que da el menor porcentaje es la de 5 capas y 100 neuronas, seguida de la de 5 capas y 90 neuronas (Figura 42). Ambas redes aportan una correlación casi perfecta (Figura 43). Al tener dudas respecto a cuál aporta un mejor resultado

debido a que su precisión es muy parecida, se evalúa el tiempo computacional y se aprecia que la red de 5 capas y 90 neuronas es más rápida por lo que se considera la mejor.

4.2.5. Elección de las funciones de transferencia

Una vez elegida la función de entrenamiento y el número de capas y neuronas se procede a la elección de función de transferencia. El programa da a elegir entre la TANSIG, PURELIN y LOGSIG, explicadas anteriormente. Además, permite elegir una función de transferencia para cada capa por lo que permite hacer combinaciones.

Se ha realizado la evaluación de 9 combinaciones, entre las cuales hay tres casos en que todas las capas usan la misma función de transferencia y 6 en que se alternan 2 funciones de transferencia.

TIPOS DE FUNCIONES DE TRANSFERENCIA

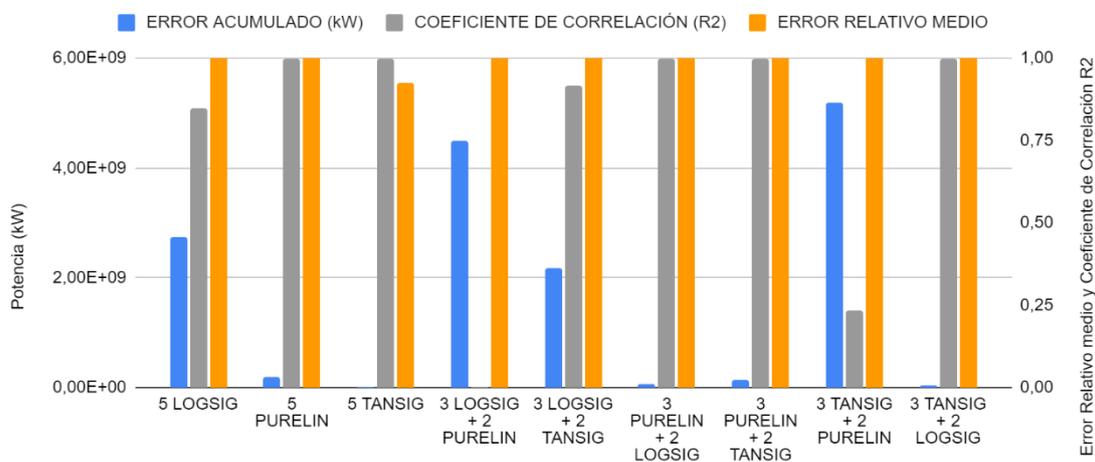


Figura 45. Comparación de los distintos tipos de funciones de transferencia

Una vez obtenidos los errores se observa en la Figura 45 que la mejor opción es la combinación de 5 TANSIG, aportando un coeficiente de correlación de 1 y un error acumulado mínimo. Además, su error relativo medio también es el más bajo, siendo menor al 1%. Este tipo de función de transferencia se explica en el apartado 0.

4.2.6. Entrenamiento de la red y simulaciones

Una vez se conocen los detalles y parámetros de la red neuronal óptima, esta se puede evaluar. Se ha considerado evaluar tres casos:

- Uso del 50% de los inversores trabajando a MPP

Primeramente, se ha entrenado una red considerando que la mitad de los inversores están trabajando a MPP. En este caso se podrá evaluar la precisión que se puede llegar a obtener con la red neuronal elegida dedicando la mitad de los inversores. En este caso tomamos uno de cada dos inversores siguiendo la distribución de la Figura 46.



Figura 46. Distribución de los inversores dedicados en la planta

Una vez entrenada la red con los datos de los primeros cinco días, mediante la herramienta *ntool* se simulan los datos de los últimos dos días (Figura 47).

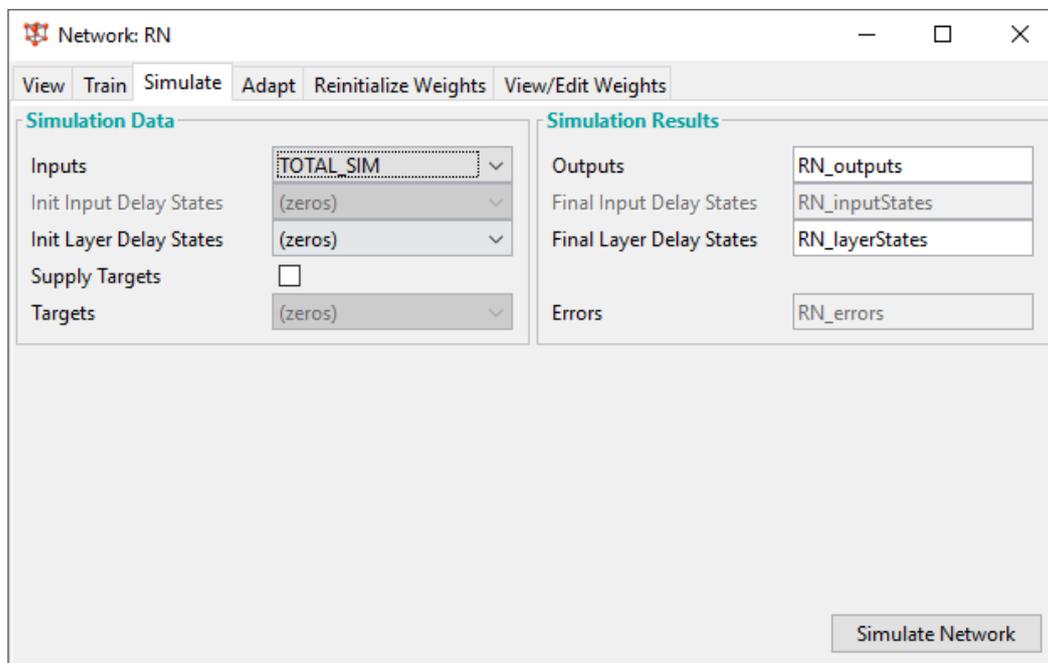


Figura 47. Interfaz del apartado de simulaciones de la herramienta *ntool*

- Uso del 10% de los inversores trabajando a MPP

Una vez evaluada la red neuronal trabajando con el 50% de los inversores a MPP, consideramos reducir drásticamente el número de inversores dedicados a MPP hasta el valor más cercano al 10%, que sea inferior al 10% para asegurar que en cualquier caso la planta es capaz de reducir su potencia producida hasta el 10% de su máximo. En este caso al haber 131 inversores el 10% sería 13,1 y, para asegurar que se puede bajar como mínimo hasta el 10% de la potencia máxima se procede a utilizar 13 inversores trabajando a MPP. Para ello hay que localizar de forma correcta los inversores MPP para abarcar bien toda la planta. Como se explica anteriormente, hay que decidir las limitaciones de las zonas de control de manera que abarquen todo el terreno para posteriormente dedicar un inversor de cada zona de control. En el caso que nos concierne, la localización de los inversores en MPP más efectiva es la siguiente (Figura 48):

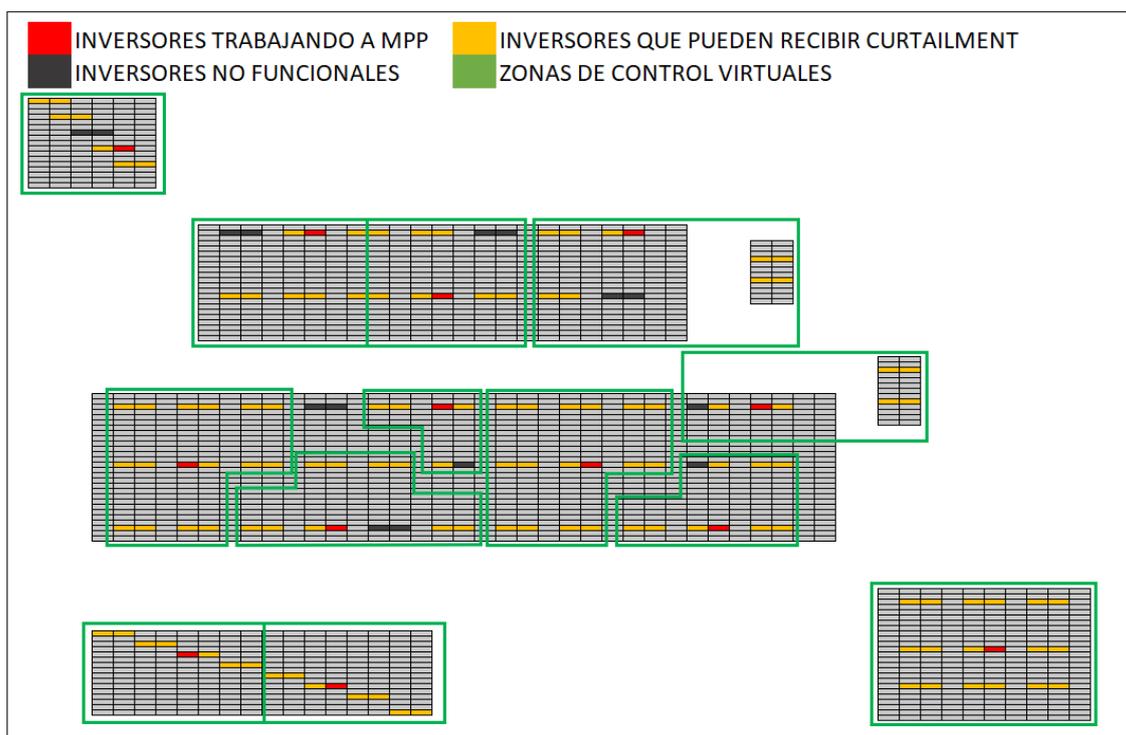


Figura 48. Distribución de los inversores dedicados y sus zonas de control en la planta

En dicha distribución se intenta maximizar el alcance de los inversores trabajando a MPP.

Una vez elegidos los inversores MPP se procede a entrenar la red con los datos de los primeros 5 días. Seguidamente se simulan los datos de los últimos 2 y se obtienen los resultados estimados.

- Método NREL

Posteriormente se aplica el método NREL partiendo de los mismos inversores dedicados y su misma localización (Tabla 3).

Tabla 3. Número de inversores asociados a cada inversor dedicado

Nº Inversor Dedicado	1	2	3	4	5	6	7	8	9	10	11	12	13
Nº Inversores asociados	7	7	7	9	4	6	15	15	9	8	7	7	17

En este caso la potencia disponible de la planta es la suma de las potencias disponibles de cada zona, y estas potencias disponibles son la potencia disponible del inversor dedicado multiplicada por el número de inversores asociados más uno, el propio inversor dedicado.

5. Validación y análisis de los resultados

Para comprobar que la red neuronal es efectiva y válida se evalúan los resultados obtenidos mediante la simulación de la red neuronal. Al haber tomado los datos de los dos últimos días, los cuales no se han utilizado para el entrenamiento de la red neuronal, para calcular la potencia disponible estimada podemos validar los resultados obtenidos mediante la comparación de la potencia disponible estimada con la potencia disponible real, la cual se ha calculado en el pretratamiento de datos.

Se consideran múltiples funciones matemáticas para que la comparación de los resultados sea lo más precisa y correcta posible. Las funciones utilizadas son las siguientes:

- Error absoluto acumulado. Se calcula la suma del valor absoluto de la diferencia entre el valor estimado y el valor real. Mediante esta función podemos ver el error acumulado de manera que los valores cercanos a 0 no alteren la medida, como puede pasar en el caso de las funciones relativas.
- Error relativo medio. En este caso se calcula el error relativo medio, siendo el error relativo el valor absoluto de la diferencia entre el valor estimado y el real dividido entre el valor real. De esta manera se obtiene una medida porcentual media que da una visión global del error relativo.
- Error relativo medio para valores >2000 kW. El error relativo medio se ve muy afectado por los valores iniciales y finales debido a que son cercanos a 0, por lo que, al dividir la diferencia entre el valor estimado y real, entre el valor real, el resultado aumenta desproporcionadamente. Consecuentemente, el valor del error relativo medio no es representativo. Se considera despreciar los valores inferiores a 2000 ya que son periodos de nulo interés debido a la baja producción de energía.
- Coeficiente de correlación R2. El coeficiente R2 determina la precisión de la aproximación por regresión ajustada. Es el porcentaje de la variación en la variable de respuesta que es explicado por un modelo lineal.
- Coeficiente de correlación de Spearman. Este coeficiente es una medida no paramétrica de la correlación de rango. Mide la intensidad y la dirección de asociación entre dos variables.
- Error cuadrático medio (RMSE). El RMSE mide la raíz del promedio de los errores al cuadrado. Este indicador incorpora tanto la varianza como el sesgo.

5.1. Análisis Red 50%

Una vez obtenidos los resultados de la simulación de los dos últimos días en la red con el 50% de los inversores trabajando a MPP, se comparan con los valores reales de potencia disponible.

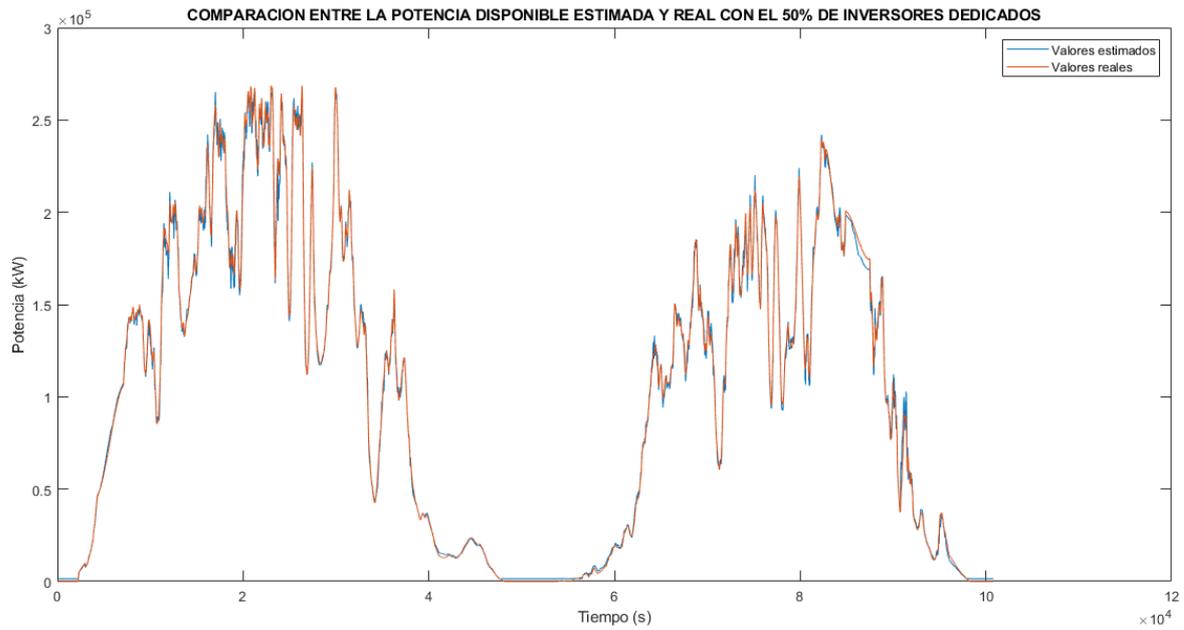


Figura 49. Comparación entre la potencia disponible estimada y real

En la Figura 49 ya se puede apreciar que la precisión es muy alta y que la simulación da unos valores que se adaptan muy bien a los patrones de la potencia disponible.

Para saber si realmente la red es precisa se calculan los resultados de las funciones anteriormente mencionadas.

Tabla 4. Funciones de error para la simulación del 50% de inversores dedicados

Función	Valor
Error absoluto acumulado	2,128e+08 kW
Error relativo medio	100,736 %
Error relativo medio para valores >2000 kW	0,0326 %
Coefficiente de correlación R2	0,9993
Coefficiente de correlación de Spearman	0,9985
RMSE	3,044e+03 kW

En la Tabla 4 se encuentran los resultados de evaluar las distintas funciones de error. El error absoluto acumulado es bastante bajo teniendo en cuenta la magnitud de los datos, que pueden llegar a picos de 288.000 kW. Este se distribuye de manera parecida a la potencia disponible, siendo constante e igual al *bias* global durante los tramos en que la potencia disponible es 0, como se ve en la Figura 50. Error absoluto para el caso del 50% de inversores dedicados (Figura 50).

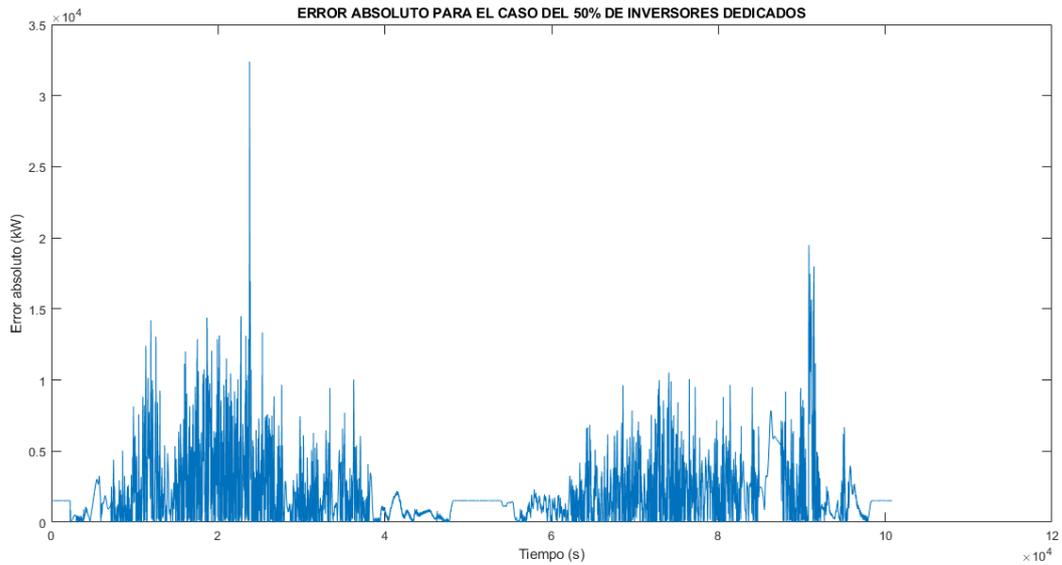


Figura 50. Error absoluto para el caso del 50% de inversores dedicados

El error relativo medio se ve alterado por aquellos valores de baja potencia, como se ve en la Figura 51. Esto es debido a que la aproximación se ve alterada por los *bias* del modelo que son constantes y no se anulan nunca. Consecuentemente, en esos tramos el error relativo se dispara. Si se evalúa el error relativo medio para valores >2000kW podemos ver cómo el error relativo es menor al 0,1%. Este dato confirma que el error absoluto acumulado es muy bajo y que el error relativo medio se ve alterado por los *bias*.

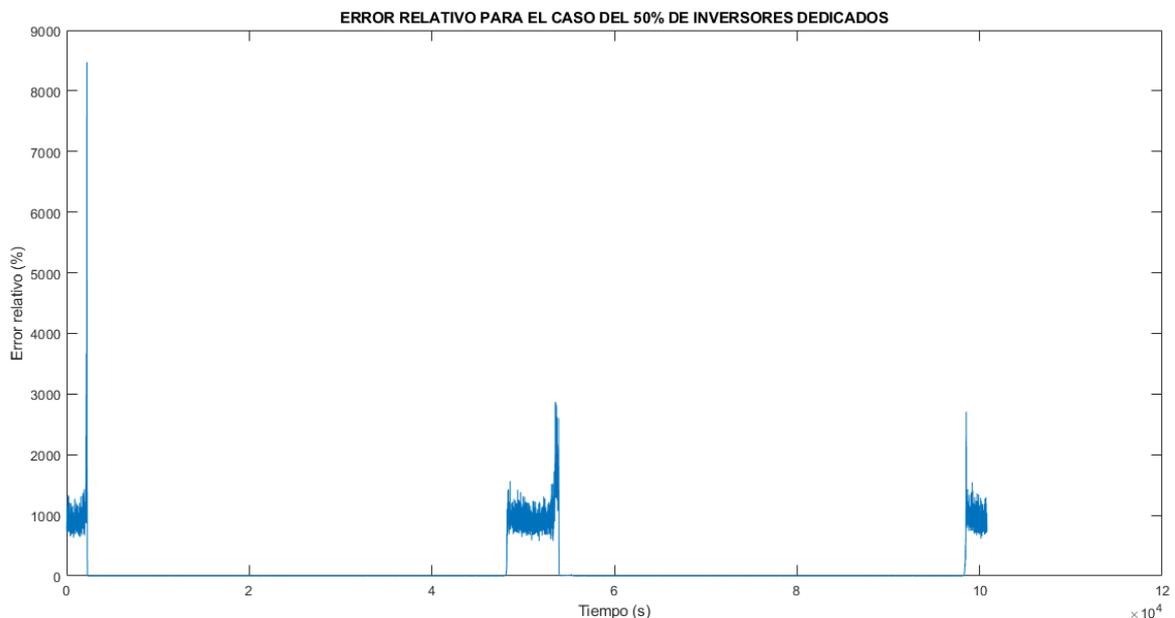


Figura 51. Error relativo para el caso del 50% de inversores dedicados

Al ser los coeficientes de correlación muy cercanos a 1 podemos asegurar que la simulación se adapta muy bien a los patrones de la potencia disponible y que es altamente precisa.

5.2. Análisis Red 10%

Una vez simulado el caso del 50% se procede al análisis de la red en que se dedica un 10% de los inversores a trabajar a MPP. Primeramente, se entrena la red durante 6h (Figura 52).

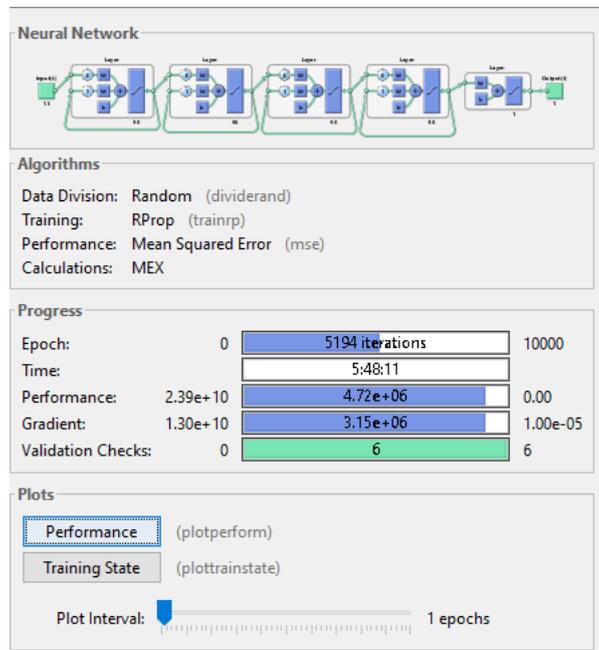


Figura 52. Resumen del entrenamiento de la Red 10%

En este caso la precisión de la red debería disminuir con respecto a la del 50% debido a que hay menos información con la que predecir. Esta disminución se puede apreciar de forma gráfica en la Figura 53.

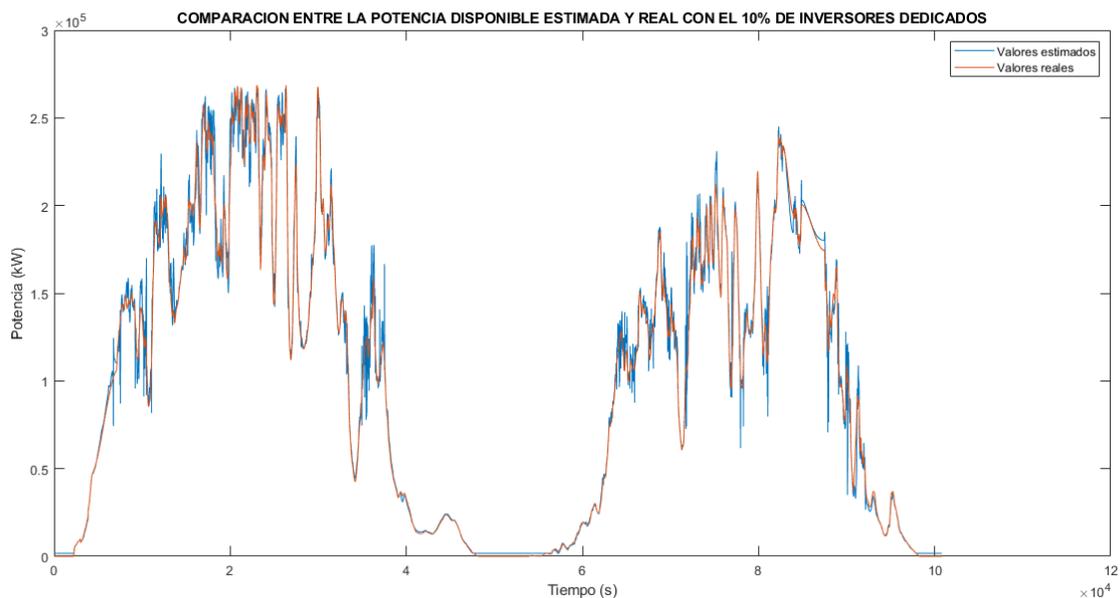


Figura 53. Comparación entre la potencia disponible estimada y real con el 10% de inversores dedicados

Este es el caso de mayor interés debido a la capacidad de disminuir la potencia hasta el 10% de la potencia disponible; por ello, se debe comprobar que no se pierda mucha precisión al disminuir el número de inversores dedicados.

Tabla 5. Funciones de error para la simulación del 50% de inversores dedicados

Función	Valor
Error absoluto acumulado	3,669e+08 kW
Error relativo medio	113,997 %
Error relativo medio para valores >2000 kW	0,0396 %
Coefficiente de correlación R2	0,9974
Coefficiente de correlación de Spearman	0,9958
RMSE	6,019e+03 kW

Una vez calculadas las múltiples funciones de error (Tabla 5), se observa cómo tanto el error absoluto como el RMSE han aumentado. Al evaluar el error relativo medio para valores >2000 kW también se aprecia que el aumento no ha sido muy significativo. Dicho error sigue siendo menor que 0,01 % por lo que se puede considerar que sigue siendo un error muy bajo. También han disminuido los dos coeficientes de correlación, pero siguen siendo muy cercanos a 1. El error relativo medio se ve afectado por los mismos fenómenos que en el caso del 50% de inversores dedicados. A efectos prácticos la red ha perdido precisión, pero sigue siendo muy precisa.

5.2.1. Análisis detallado de los errores

Al ser esta red la de mayor interés, en este apartado se estudian en profundidad sus errores.

En el caso de la predicción de la potencia disponible de la planta para trabajar un 10% por debajo de su capacidad, y así ser capaces de inyectar ese porcentaje extra en caso de ser necesario, es importante que la predicción sea de muy alta calidad para evitar que, por culpa de un error, no se llegue a poder inyectar toda la energía requerida por los *grid codes*. Para ello hay que analizar en profundidad el signo de los errores. Se puede llegar a dar 3 casos:

- Estimación ideal de la potencia disponible

En este caso la potencia estimada sería igual a la disponible real, sin existir ningún error de estimación. La planta sería capaz de inyectar el 10% extra de la potencia nominal en caso de ser requerido (Figura 54).



Figura 54. Estimación ideal de la potencia disponible

- Subestimación de la potencia disponible

En este caso la potencia estimada sería inferior a la potencia disponible real. Se produciría un error de estimación a la baja. Al ser la potencia entregada proporcional a la potencia estimada, esta se vería reducida y, consecuentemente, la reserva de potencia aumentaría. Este error supondría un déficit productivo, pero no supondría el incumplimiento del *grid code* ya que podría cubrir sobradamente la inyección del 10% de la potencia nominal (Figura 55).

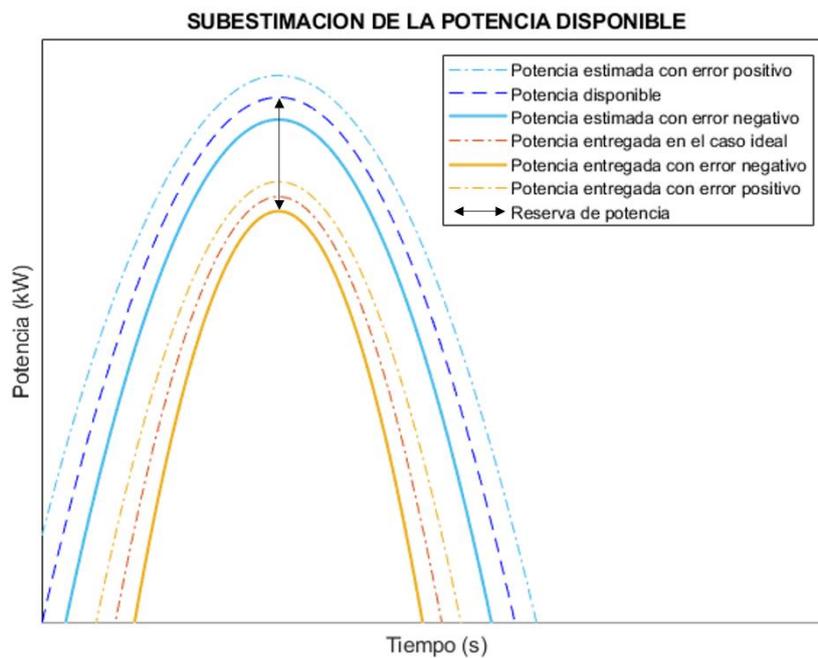


Figura 55. Subestimación de la potencia disponible

- Sobreestimación de la potencia disponible

Cuando la potencia estimada es superior a la potencia disponible real se produce el error de mayor importancia. En este caso, al sobreestimar la potencia también se ve aumentada la potencia entregada, dando lugar a una potencia entregada con error positivo. Consecuentemente, la reserva de potencia se ve reducida por lo que en caso de que se requiera inyectar potencia a la red, la planta no será capaz de suministrarla, produciéndose así el incumplimiento del *grid code* (Figura 56).

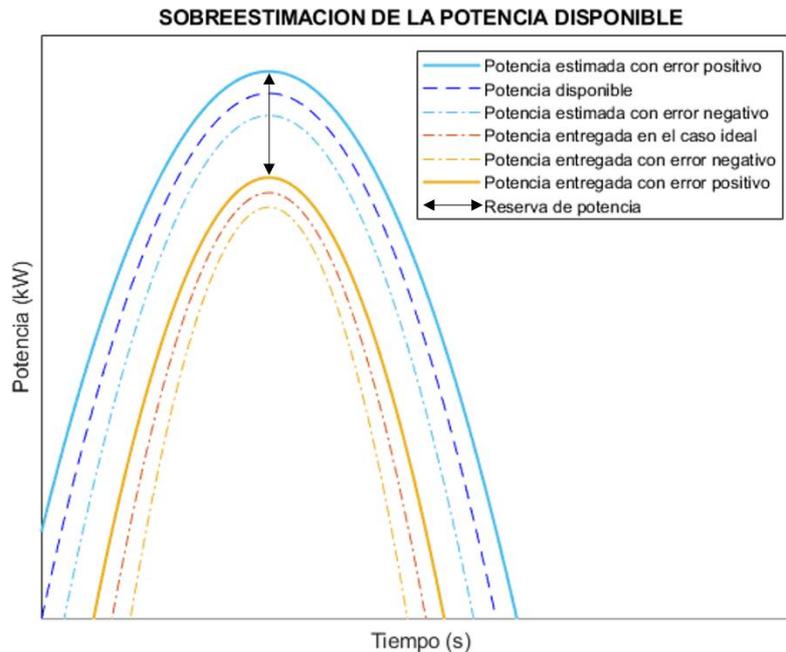


Figura 56. Sobreestimación de la potencia disponible

Para solventar la problemática de la sobreestimación de la potencia disponible se propone una solución que pueda asegurar que no se producirá un error de sobreestimación, con un intervalo de confianza del 95%, a costa de que aumente el error de subestimación.

Primeramente, se analizan los errores obtenidos y su signo (Figura 57 y Figura 58). El error se calcula con la diferencia entre la potencia estimada y la real y el error relativo dividiendo el error entre los valores reales. Para ambos errores se consideran solo los tramos en que se produce más de 2000 kW para evitar alteraciones debidas a los *bias* en tramos de poco interés, como se ha hecho ya anteriormente.

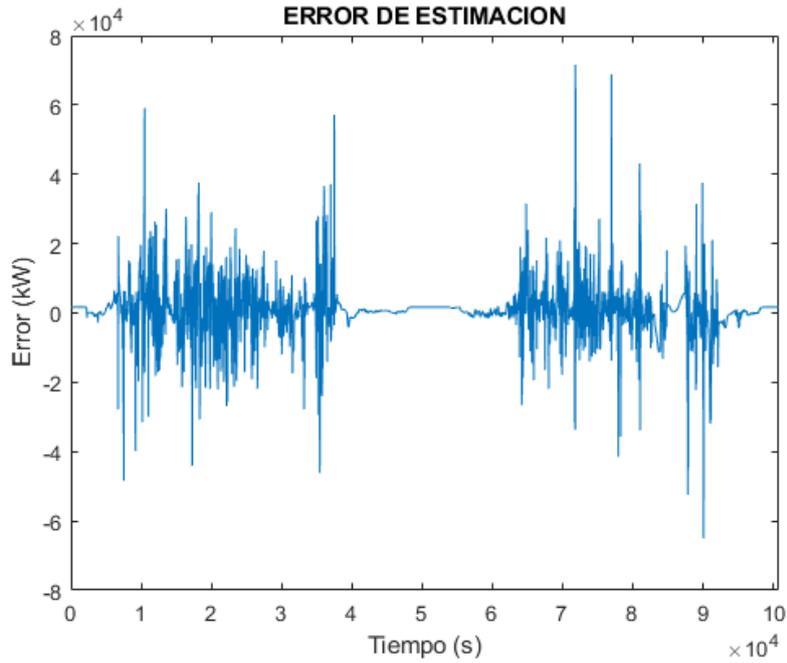


Figura 57. Error de estimación

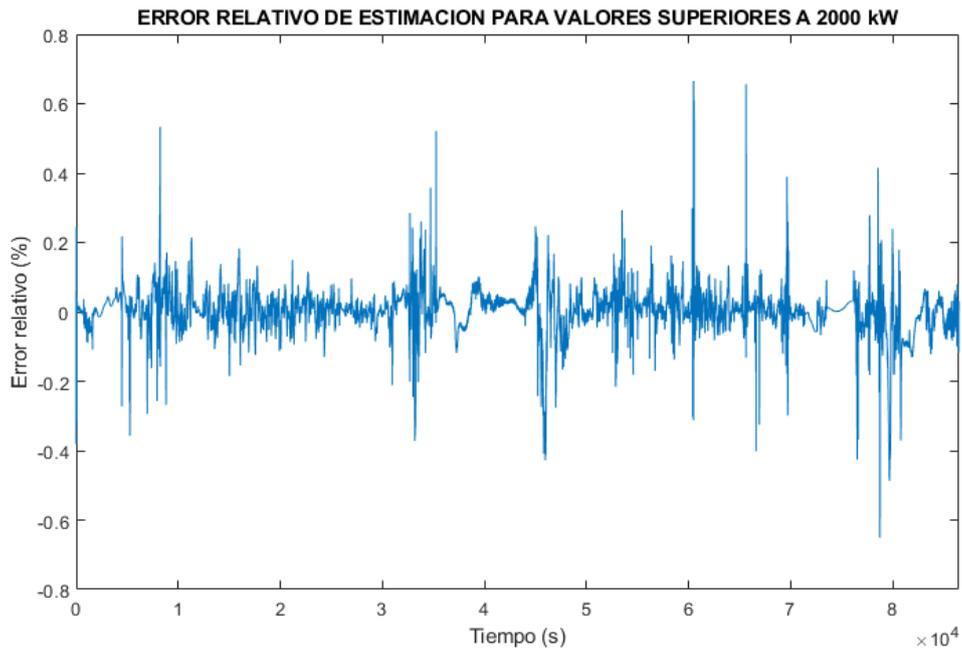


Figura 58. Error relativo de estimación para valores superiores a 2000 kW

Se proponen dos alternativas:

- Calibración mediante el error

Para ello, mediante la herramienta de análisis de datos MiniTab® se analiza el histograma de los datos y se calcula su intervalo de confianza del 95% (Figura 59). Para asegurar que, como mínimo en el 95% de los casos, el valor del error será cero o negativo y, por tanto, no se incumplirá la capacidad mínima de inyección extra de potencia del 10% (*grid code*) se decide restar a la

potencia estimada el valor superior del IC. En este caso dicho valor son 11.364 kW. Esta resta se aplicaría solo a los valores de potencia estimada superiores a dicho valor, considerando nulos los valores inferiores. Esta alternativa supone la pérdida extra de 1,041e+09 kW entre los dos días analizados.

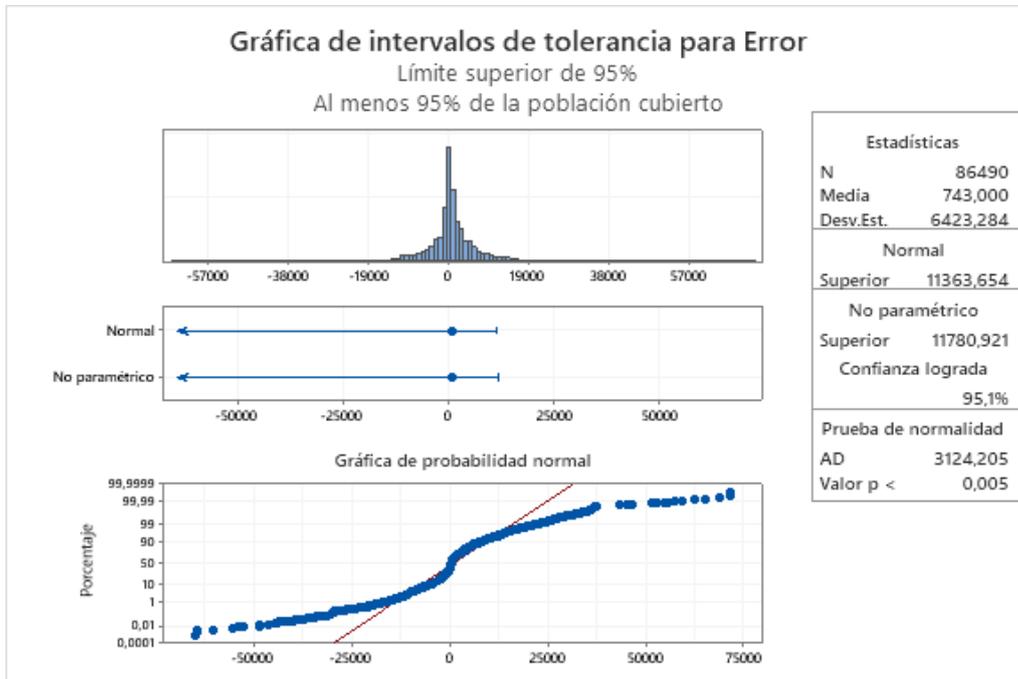


Figura 59. Gráfica de intervalos de tolerancia para el error

- Calibración mediante el error relativo

En este caso se propone seguir el método anterior, pero usando el error relativo. Se calcula el intervalo de confianza del 95% y se aplica la disminución porcentual del límite superior del IC a la potencia estimada (Figura 60). En este caso sería un 0,103%. Al aplicarlo se perderían 9,645e+08 kW. Este método permite menores pérdidas que el anterior por lo que se considera más adecuado.

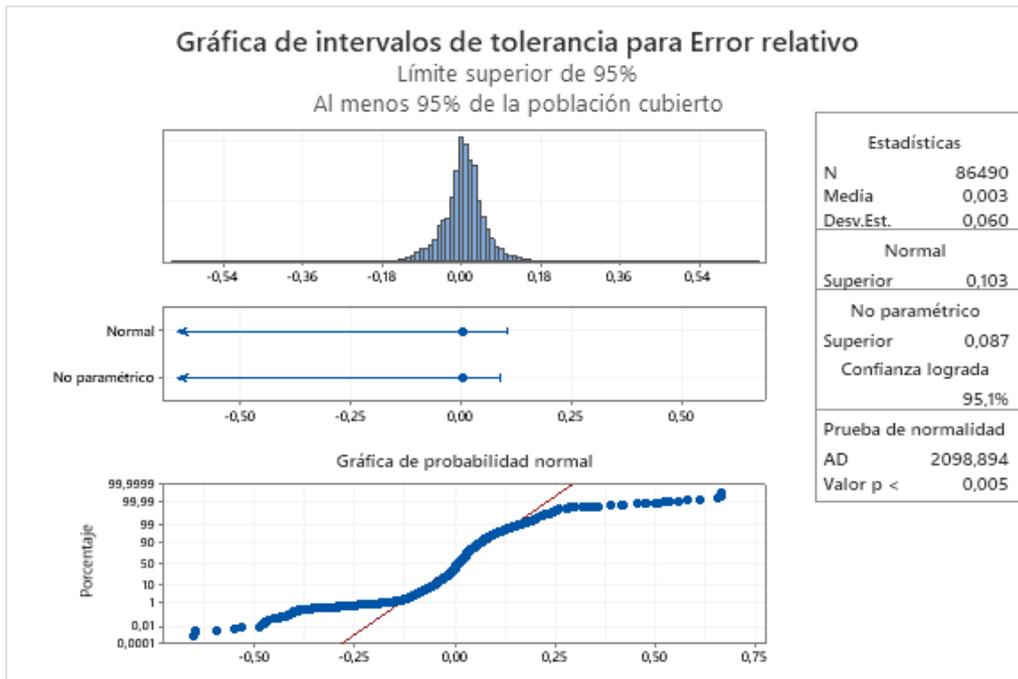


Figura 60. Gráfica de intervalos de tolerancia para el error relativo

De esta manera, se asegura que durante un 95% del tiempo la planta será capaz de proporcionar las reservas de energía a costa de una menor producción nominal (Figura 61). Al aplicar estos cambios la distribución deja de ser normal por lo que se evalúa como no paramétrica.

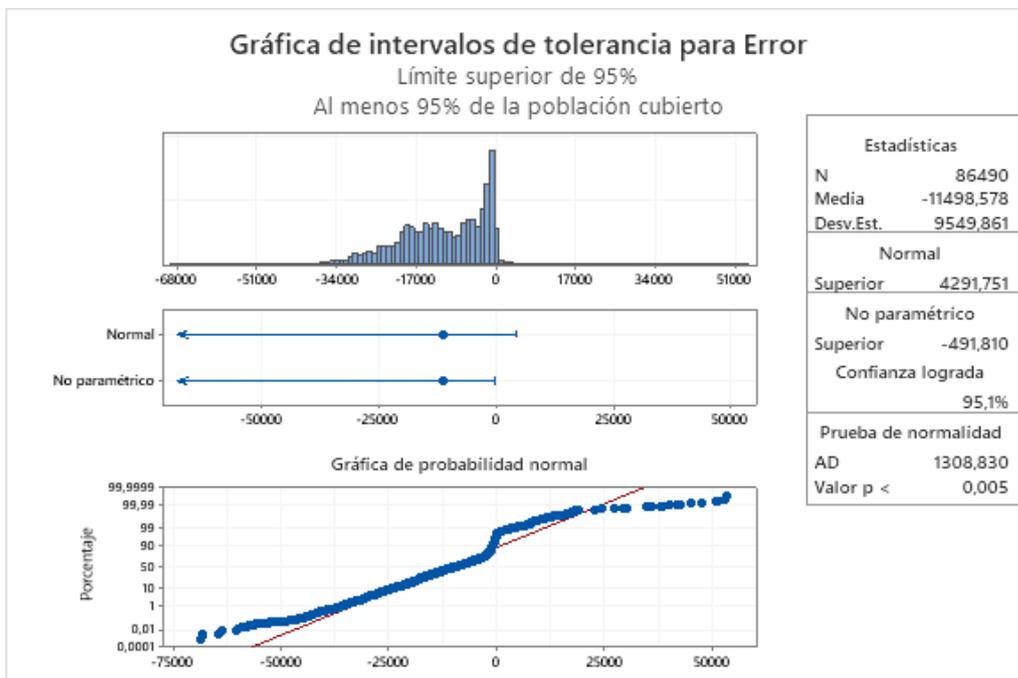


Figura 61. Gráfica de intervalos de tolerancia para el error corregido

5.3. Comparación con el método NREL

Una vez visto el caso del 10% de inversores dedicados y su estimación de la potencia disponible mediante redes neuronales se procede con el análisis de los resultados obtenidos mediante el método NREL.

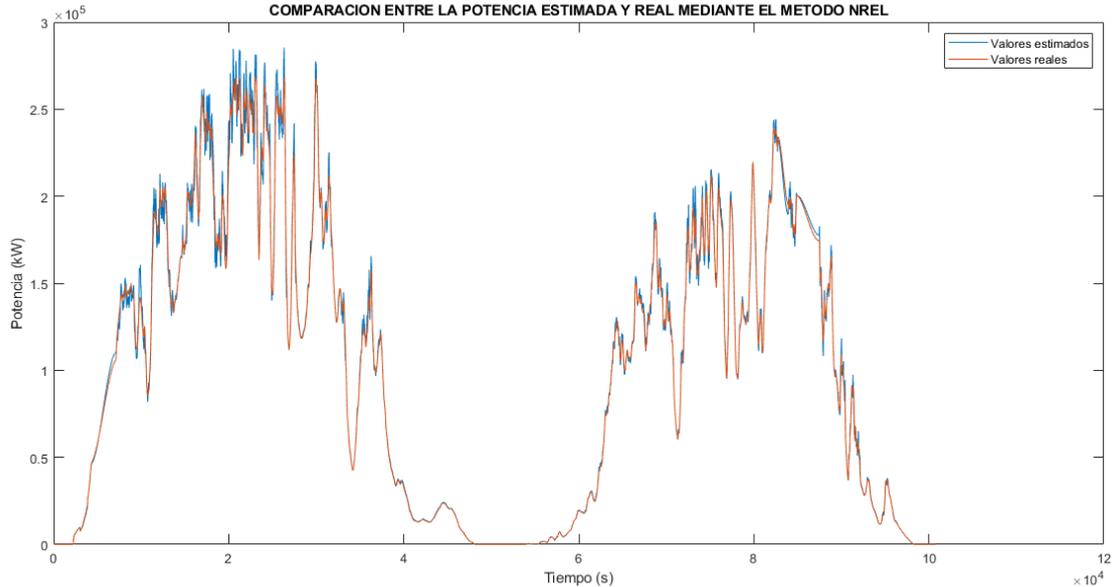


Figura 62. Comparación entre la potencia estimada y real mediante el método NREL

Como se puede ver en la Figura 62, la aproximación mediante el método NREL también parece ser bastante precisa y, en algunos tramos, mejor que las realizadas mediante redes neuronales. Como se aprecia en la Figura 63, no hay un error constante en los tramos en que la potencia disponible es nula, como sí pasa en la Figura 53. Eso es debido a que en este caso no afectan de ninguna manera los *bias* que producían ese error. De todas maneras, esos tramos son de muy poco interés por lo que no suponen una clara mejoría respecto a las simulaciones mediante redes neuronales.

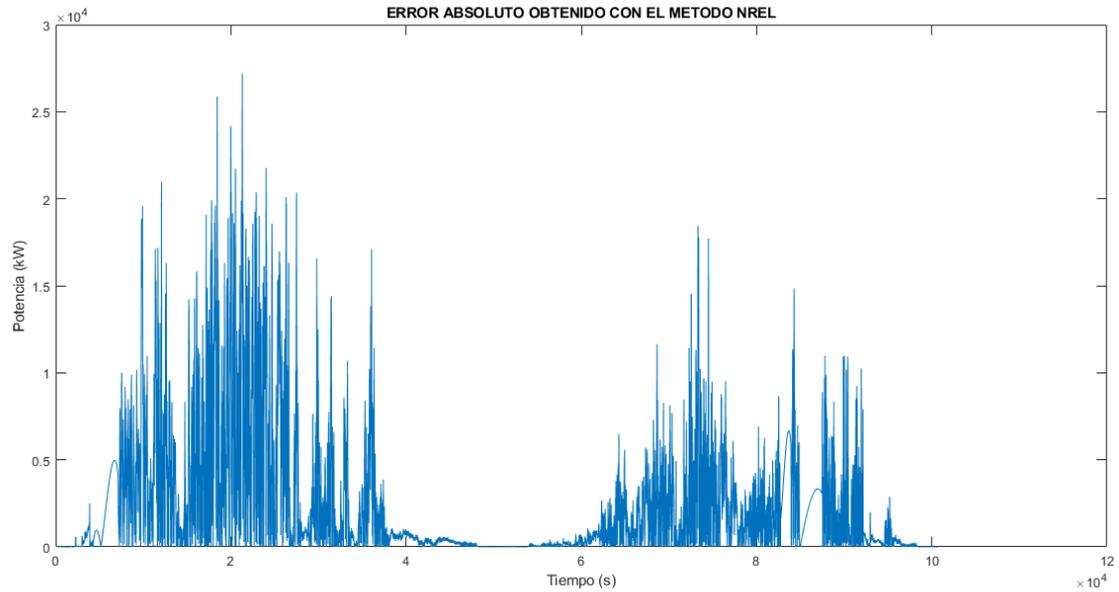


Figura 63. Error absoluto obtenido con el método NREL

Una vez visto de forma visual cómo de precisa es la red, obtenemos los valores de las funciones de error para cuantificar esta precisión (Tabla 6 Tabla 6. Funciones de error para el método NREL).

Tabla 6. Funciones de error para el método NREL

Función	Valor
Error absoluto acumulado	2,384e+08 kW
Error relativo medio	0,0634 %
Error relativo medio para valores >2000 kW	0,0219 %
Coefficiente de correlación R2	0,9988
Coefficiente de correlación de Spearman	0,9982
RMSE	4,1958e+03 kW

Este caso en concreto da una precisión más elevada que mediante el uso de redes neuronales. Aporta un menor error global y relativo además de una mejor correlación (Figura 64).

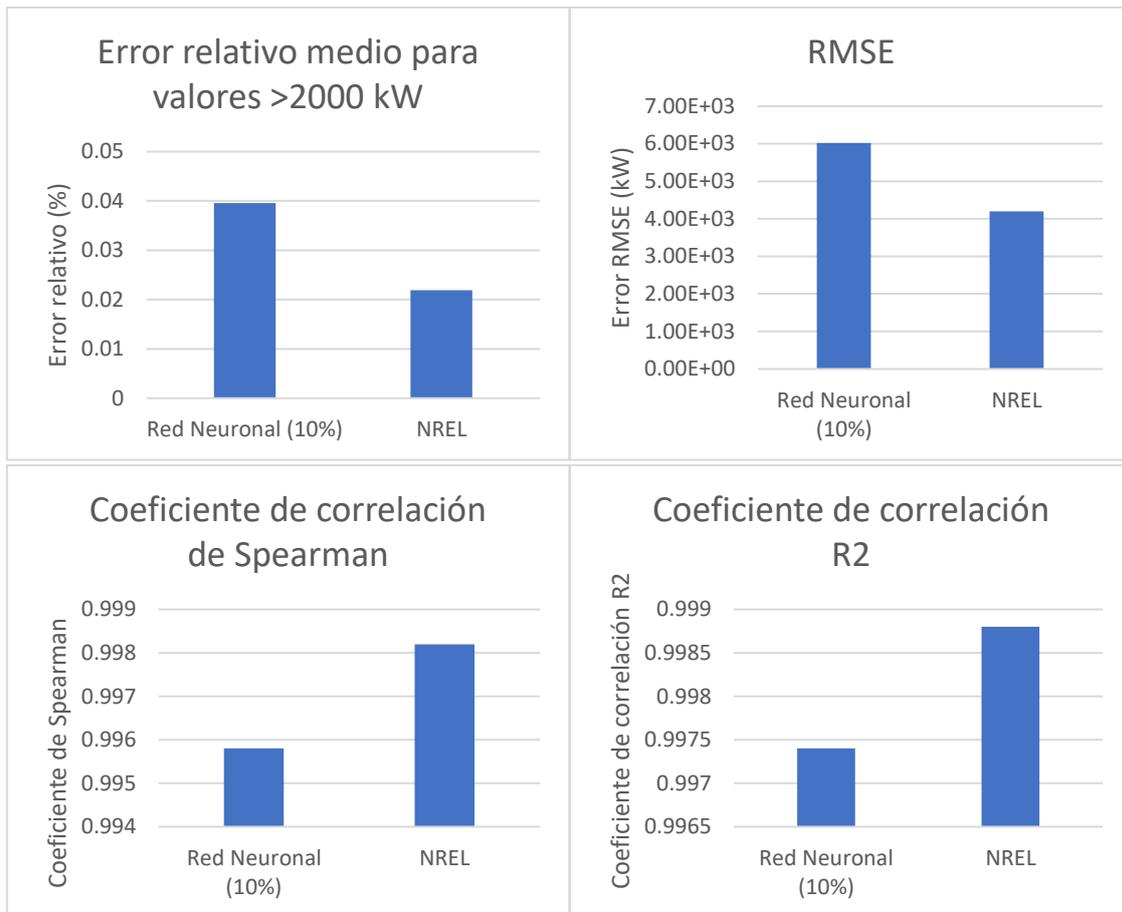


Figura 64. Comparación del error entre la Red 10% y el método NREL

5.3.1. Análisis de la robustez

Como se ha visto en el pretratamiento de datos, es algo común que algunos inversores den lecturas nulas o erróneas en ciertos periodos de tiempo. Debido a la posibilidad de que uno de los inversores dedicados obtenga valores de lectura nulos o alterados se procede a comparar la robustez de ambas redes.

Se supone que uno de los inversores dedicados falla y da valores nulos para analizar cómo afectaría un posible fallo a los resultados obtenidos por ambas redes. Para ello se vuelven a analizar los parámetros de error de cada caso y se comparan.

En el caso la red neuronal del 10% de inversores dedicados se aprecia cómo aumenta el error sin llegar a dar un valor desproporcionadamente alto. El error absoluto y el RMSE son inferiores a los obtenidos mediante el método NREL. Aun así, el método NREL sigue dando mejores coeficientes de correlación, así como menor error relativo (Tabla 7).

Ambas redes sufren un ligero aumento del error, pero siguen siendo robustas y dando altas precisiones en caso de que falle uno de sus inversores.

Tabla 7 Comparación de los errores de la Red 10% y del método NREL para la robustez

Función	Red neuronal del 10%	Método NREL
Error absoluto acumulado	8,805e+08 kW	9,691e+08 kW
Error relativo medio	114,052 %	0,1265 %
Error relativo medio para valores >2000 kW	0,1026 %	0,0943 %
Coefficiente de correlación R2	0,9925	0,9988
Coefficiente de correlación de Spearman	0,9918	0,9981
RMSE	1,256e+04 kW	1,296e+04 kW

5.4. Análisis de una nueva red neuronal

Una vez visto que el método NREL es más preciso que el método propuesto se procede a analizar una nueva red neuronal usando el método de entrenamiento LM que se descartó por falta de capacidad y tiempo computacionales. Debido a que para una red con 5 capas y 90 neuronas como la que se usaba en los casos anteriores se requerían como mínimo 120 Gb de memoria RAM, se ha repetido la selección de capas y neuronas para ver si con una red neuronal de menos capas y neuronas, pero con dicha *training function*, se obtiene una mejoría de los resultados.

Primeramente, se ha considerado reducir la cantidad de datos con los que se realiza la selección para agilizar el proceso y evitar los altos tiempos computacional. Se han reducido los datos de 705.600 valores hasta 353.000, un 50%. Aun con la reducción de datos los tiempos de entreno siguen siendo muy altos por lo que se consideran las siguientes combinaciones. Se simulan redes con 3, 4, 5 y 6 capas de 5, 10 o 15 neuronas. Al ser pocas neuronas por capa se limita mucho la capacidad de la red neuronal pero no se pueden entrenar redes neuronales de muchas neuronas sin una muy alta capacidad computacional.

Al analizar el error acumulado se puede apreciar que para redes de 5 y 10 neuronas por capa se produce el *underfitting*. En ese caso, las redes con mejores resultados son la de 5 y 6 capas, ambas con 15 neuronas por capa.

Respecto al coeficiente de correlación y al error relativo, se produce el mismo efecto que en caso del error acumulado, dándose los mejores valores en las redes de 4, 5 y 6 capas y con 15 neuronas por capa (Figura 65).

También se puede apreciar el fenómeno de *underfitting* en el tiempo de computación de las distintas redes neuronales. En caso de que se produzca, el tiempo de computación es extremadamente bajo ya que el programa considera que ya ha entrenado hasta el punto óptimo la red. Las redes que dan valores correctos también requieren un muy alto tiempo de computación.

ELECCIÓN DEL NÚMERO DE CAPAS Y NEURONAS

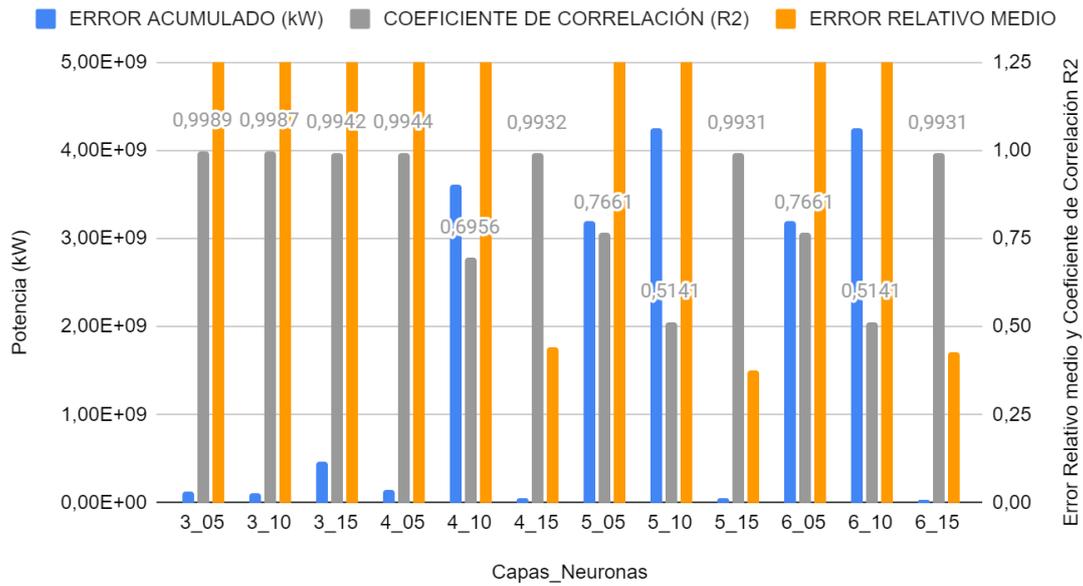


Figura 65. Comparación de las diferentes combinaciones de capas y neuronas para el método LM

Una vez analizados los distintos tipos de redes neuronales se procede con el análisis de las dos mejores opciones, la de 5 capas y 15 neuronas por capa y la de 6 capas y 15 neuronas por capa.

5.4.1. Red de 5 capas y 15 neuronas por capa

Una vez obtenida la estructura de la red neuronal se procede al entrenamiento de dicha red con los datos de los primeros 5 días. Este entrenamiento implica un alto coste computacional, ha requerido de un ordenador de 16GB de RAM, y 27h 45min de cálculo ininterrumpido (Figura 66).

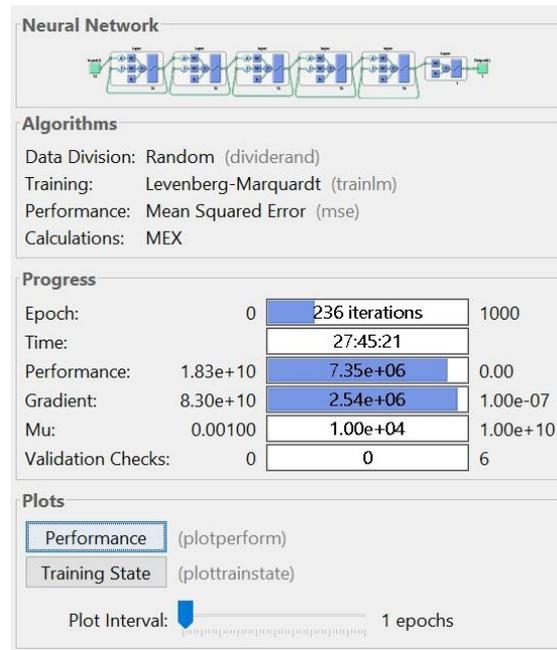


Figura 66. Resumen del entrenamiento de la Red LM con 5 capas y 15 neuronas

Primeramente, se comparan de manera visual la potencia disponible estimada y real, y se observa que la red se adapta bastante bien a la potencia disponible (Figura 67).

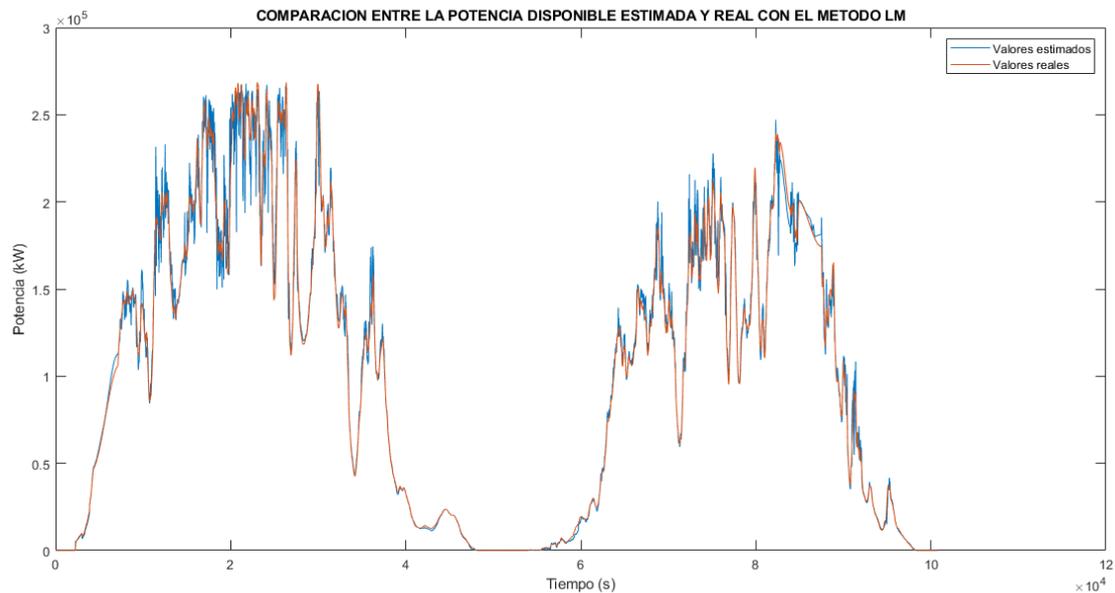


Figura 67. Comparación entre la potencia disponible estimada y real con el método LM con 5 capas y 15 neuronas

Para conocer en detalle la precisión de la red calculada se procede al análisis de los parámetros de error (Tabla 8).

Tabla 8. Funciones de error para la red LM con 5 capas y 15 neuronas

Función	Valor
Error absoluto acumulado	3,744e+08 kW
Error relativo medio	8,632 %
Error relativo medio para valores >2000 kW	0,0417 %
Coefficiente de correlación R2	0,9968
Coefficiente de correlación de Spearman	0,9963
RMSE	6,564e+03 kW

Los errores indican que la red neuronal inicial es más precisa y aporta menos error. Solamente los coeficientes de relación son mejores en este caso que en el inicial. Sigue siendo una red muy precisa cuyo error es muy bajo, pero no se consigue mejorar ni la red inicial ni el método NREL.

5.4.2. Caso de 6 capas y 15 neuronas

Una vez visto que la red con 5 capas y 15 neuronas no mejora la red inicial ni los resultados obtenidos mediante el método NREL, se procede al análisis de la red de 6 capas y 15 neuronas. Este análisis implica un mayor coste computacional y 22h 24min de cálculo ininterrumpido (Figura 68). Este cálculo se ha realizado con un ordenador de 64GB de RAM.

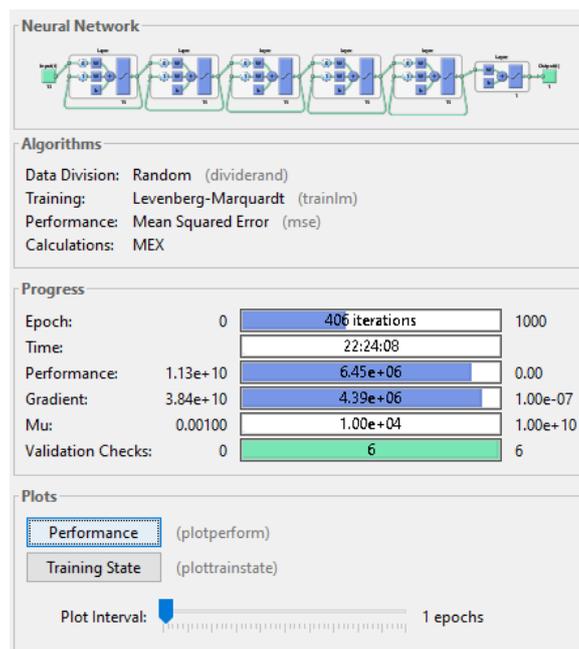


Figura 68. Resumen del entrenamiento de la Red LM con 6 capas y 15 neuronas

Una vez entrenada la red neuronal se ha simulado y se han obtenido unos resultados que se adaptan mejor a los patrones de la potencia disponible (Figura 69).

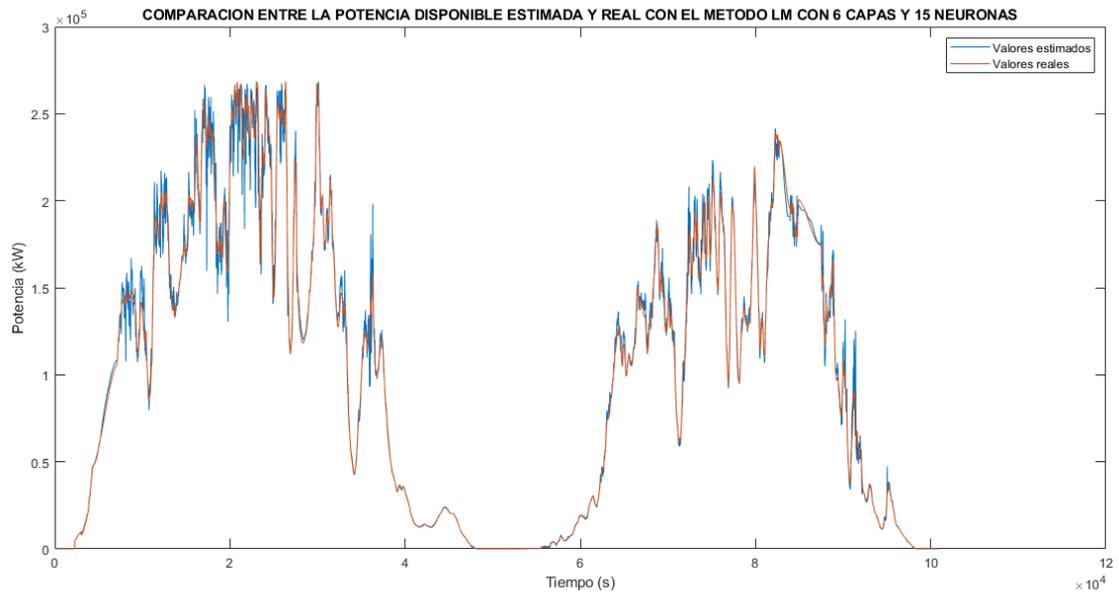


Figura 69. Comparación entre la potencia disponible estimada y real con el método LM con 6 capas y 15 neuronas

Seguidamente se procede al análisis de los errores (Tabla 9).

Tabla 9. Funciones de error para la red LM con 6 capas y 15 neuronas

Función	Valor
Error absoluto acumulado	3,4290e+08 kW
Error relativo medio	9,384 %
Error relativo medio para valores >2000 kW	0,0324 %
Coefficiente de correlación R2	0,9972
Coefficiente de correlación de Spearman	0,9963
RMSE	6,128e+03 kW

Se puede apreciar una mejoría en precisión, más concretamente se consigue una mejor precisión que en el caso de la red neuronal inicial, aunque aún no se logra superar la precisión del método NREL.

6. Conclusiones

En este TFG se ha analizado la posibilidad de utilizar redes neuronales como herramienta para la estimación de potencia de una LS-PVPP para dar una alternativa al uso de ESS.

En este apartado se resumen las conclusiones obtenidas.

6.1. Conclusiones referidas a red neuronal a utilizar

Se han analizado, en primer lugar, 68 distintas redes neuronales. Los parámetros que se han modificado han sido:

- Tipo de red neuronal. Se han analizado 5 tipos distintos de red neuronal hasta determinar que la óptima es la *Layer recurrent*
- Tipos de *training function*. Se han analizado 14 distintas *training functions* llegando a una conclusión inicial de que la que mayor precisión aportaba en función del tiempo de computación es la RProp.
- Tipos de función de transferencia. Se han analizado 9 combinaciones de 3 tipos distintos de funciones de transferencia, obteniéndose que la mejor combinación de funciones se da con el uso de la tangente hiperbólica (TANSIG) en todas las capas.
- Número de capas y neuronas. Se han desarrollado 40 redes, de 4, 5, 6 y 7 capas combinándolas con 10, 20, 30, 40, 50, 60, 70, 80, 90 y 100 neuronas por capa. Dándose el mejor resultado con 5 capas y 90 neuronas.

Posteriormente, a la vista de los resultados obtenidos, se han analizado 12 redes adicionales. Estas redes solo variaban en la training function y en el número de capas. Con la nueva training function (Levenberg-Marquardt), se han analizado las combinaciones de 3, 4, 5 y 6 capas con 5, 10 y 15 neuronas. Con esta nueva training function, el tiempo computacional se dispara respecto a la usada inicialmente. Por ello debe limitarse el número de capas para adaptarse a la capacidad computacional disponible. Las redes que mejores resultados han proporcionado han sido la de 5 capas y 15 neuronas y la de 6 capas y 15 neuronas. Debido a la similitud en la precisión obtenida en el análisis de capas y neuronas se ha decidido analizar ambas. En los otros casos se ha producido *underfitting* por la limitación sobre el número de neuronas y capas disponible ya mencionada.

De las 3 redes analizadas, la que mejor resultados ha generado ha sido la que utiliza Levenberg-Marquardt con 6 capas y 15 neuronas con un tiempo computacional de 22h 30min. La siguiente red neuronal más precisa ha sido la que utiliza el método RProp con 5 capas y 90 neuronas. Esta segunda red ha precisado de 6h. La diferencia de precisión no justifica el aumento desproporcionado del tiempo de computación de la primera respecto a la segunda.

6.2. Conclusiones referidas a la precisión de la red elegida

Una vez se ha desarrollado la red inicial, se ha procedido al análisis de sus errores en profundidad. La utilidad de la red calculada es la predicción de la potencia disponible de la planta para poder trabajar por debajo de la capacidad de la planta y así ser capaz de inyectar un 10% de la potencia nominal o recortar dicha potencia hasta el 10% en caso de ser requerido. Al depender la potencia entregada de la potencia disponible estimada, un error de precisión puede

dar lugar al incumplimiento de los *grid codes*. Subestimar la potencia disponible implica un mayor porcentaje de potencia inyectable a la red, por lo que supone pérdidas económicas por producir por debajo del punto nominal óptimo de la planta. Sobreestimar la potencia disponible es el peor de los casos ya que implica el incumplimiento de los *grid codes*, un error que supondría sanciones a la LS-PVPP.

El histograma del error toma forma de distribución normal centrada ligeramente por encima del cero. Para evitar la sobreestimación se han estudiado dos alternativas que consiguen un índice de confianza del 95% y se ha valorado cuál es la óptima. La primera alternativa es restar un valor fijo de potencia para desplazar el histograma de errores hasta que el valor del error límite superior del índice de confianza sea cero o negativo. La segunda es analizar el histograma del error relativo y repetir el proceso anterior con el error relativo del límite superior del índice. Una vez analizadas las pérdidas de potencia que supondría cada alternativa se decide que la óptima es corregir la estimación de potencia disponible mediante el error relativo. Esta alternativa implica unas pérdidas extras de 9,645e08 kW a lo largo de los dos días de análisis, mientras que la del valor fijo supone unas pérdidas extras de 1,041e09 kW.

6.3. Conclusiones referidas a la mejoría respecto a métodos existentes

El uso de redes neuronales para la predicción de la potencia disponible surge como alternativa a otros métodos de predicción ya existentes, entre los cuales destaca el método NREL. Se ha realizado una comparación en que se ha valorado la precisión de la estimación y el tiempo y capacidad computacionales requeridos. Además, existe la posibilidad de que los inversores dedicados den lecturas erróneas o nulas, como ha pasado con algunos inversores de la planta estudiada. Dada esta posibilidad también se ha valorado estudiar la robustez de ambos métodos para valorar cuál se ve menos afectado y da una mejor precisión en caso de que un inversor dedicado falle.

Al comparar los resultados obtenidos de las 3 redes neuronales con los del método NREL se aprecia cómo no se ha conseguido mejorar la precisión del método NREL con la capacidad computacional disponible. La red que más se ha acercado ha sido la que usa el método LM con 6 capas y 15 neuronas, por lo que se intuye que con una mayor capacidad computacional quizás se podría superar la precisión del método NREL. El método NREL es óptimo en cuanto a tiempo computacional, al ser casi nulo, comparado con la capacidad y tiempo requeridos por las redes neuronales que más precisión han dado. La robustez ha resultado parecida, dando menor error absoluto la red neuronal pero mayor error relativo y peores coeficientes de correlación de Spearman y R2.

6.4. Recomendaciones

Una vez se ha analizado y comparado el método propuesto se procede a analizar qué alternativa puede ser de mayor utilidad.

De las anteriores conclusiones se deduce que el método desarrollado requiere de un moderado coste computacional y no consigue mejorar los resultados obtenidos mediante el método NREL. Aun así, este método es altamente preciso y permite una muy buena estimación de la potencia disponible.

Con los resultados de la red neuronal entrenada mediante la *training function* LM también se puede ver una tendencia a mejorar la precisión a medida que se aumentan las neuronas, aunque también aumente el coste computacional.

Existen múltiples LS-PVPP que, por su localización, sufren de cambios constantes en la meteorología que hacen que su producción sea muy variable y consideren trabajar por debajo del MPP para así evitar el uso de ESS. Para aquellas LS-PVPP que opten por este método y cuyas capacidades computacionales no sean muy elevadas, es recomendable usar el método NREL para la predicción de la energía disponible.

En caso de que se disponga de altas capacidades computacionales se recomienda analizar redes neuronales con la *training function* LM aumentando el número de neuronas por capa debido a la tendencia creciente de la precisión vista en el presente trabajo. En caso de que se mejore el error mediante mayores capacidades computacionales, se puede conseguir disminuir el error por sobreestimación de la potencia disponible. Consecuentemente, si se reduce el error por sobreestimación no se debe reducir tanto el valor de potencia estimada disponible para evitar el incumplimiento de *grid codes* dando lugar a una producción óptima.

Bibliografía

- [1] I. E. Agency, *CO2 emissions from fuel combustion- Highlights*, 2017.
- [2] K. Taylor, «Renewables overtook fossil fuels as EU's main power source in 2020,» 25 01 2021. [En línea]. Available: <https://www.euractiv.com/section/energy/news/renewables-overtook-fossil-fuel-as-main-source-of-eus-electricity-in-2020/>. [Último acceso: 12 10 2021].
- [3] E. Bullich-Massagué, «Feeder flow control and operation in large scale photovoltaic power plants and microgrids,» UPC, Barcelona, 2018.
- [4] M. Nordio, *Advanced control of PV power plants*, Barcelona: UPC, 2021.
- [5] «ComAp solution for new Grid Codes,» ComAp, [En línea]. Available: <https://www.comap-control.com/solutions/technology/grid-codes>. [Último acceso: 25 11 2021].
- [6] F. Boshell, A. Anisie y G. Nair, «Códigos de conexión a la red y estudio del cumplimiento de los códigos de red,» IRENA, 2020.
- [7] E. Bullich-Massagué, F. Cifuentes-García, I. Glenny-Crende, M. Cheah-Mañé, M. Aragüés-Peñalba, F. Díaz-González y O. Gomis-Bellmunt, «A review of energy storage technologies for large scale photovoltaic power plants,» CITCEA-UPC, Barcelona, 2020.
- [8] J. Á. Leiva Vilaplana, «Desarrollo de una metodología de estimación de potencia disponible, basada en redes neuronales artificiales, para la implementación del servicio de red under-frequency en centrales de generación fotovoltaica,» UPC, Barcelona, 2021.
- [9] J. Leisch y J. Cochran, «Forecasting wind and solar generation: Improving system operations,» NREL, 2016.
- [10] A. Dobbs, T. Elgindy, B.-M. Hodge y A. Florita, «Shot-Term Solar Forecasting Performance of Popular Machine Learning Algorithms,» NREL, Berlin, 2017.
- [11] V. Gevorgian, «Highly Accurate Method for Real-Time Active Power Reserve Estimation for Utility-Scale Photovoltaic Power Plants,» NREL, 2019.
- [12] Y. Riahi y S. Riahi, *Big Data and Big Data Analytics: Concepts, Types and Technologies*, El Jadida: University of Chouaib Doukkali, 2018.
- [13] E. C. Andrade Tepán, «Estudio de los principales tipos de redes neuronales y las herramientas para su aplicación,» Universidad Politécnica Salesiana, Cuenca (Ecuador), 2013.
- [14] J. M. Medrano, «Aplicación de técnicas de Machine Learning para la predicción de resultados deportivos,» Universidad de Alcalá de Henares, Alcalá de Henares, 2018.
- [15] A. C. Franco, «Deep Learning,» Universidad de Sevilla, Sevilla, 2019.

- [16] L. Barboni y E. Catsigeras, «Neurodinámica determinista,» Universidad de la República, Montevideo, 2016.
- [17] «Nerual networks,» GitHub, [En línea]. Available: https://ml4a.github.io/ml4a/es/neural_networks/. [Último acceso: 29 10 2021].
- [18] E. Freire y S. Silva, «Redes neuronales,» Bootcamp AI, 2019. [En línea]. Available: <https://bootcampai.medium.com/redes-neuronales-13349dd1a5bb>. [Último acceso: 29 10 2021].
- [19] J. Torres, «Redes Neuronales Recurrentes,» Jordi TORRES.AI, 22 9 2019. [En línea]. Available: <https://torres.ai/redes-neuronales-recurrentes/>. [Último acceso: 1 11 2021].
- [20] J. P. Vásquez López, «Red neuronal feedforward como estimador de patrones de corrientes en el interior del puerto de manzanillo sujeto a la acción de tsunamis,» Instituto Mexicano del Transporte, Sanfandila, 2014.
- [21] «Design Time Series NARX Feedback Neural Networks,» MathWorks, 2021. [En línea]. Available: <https://es.mathworks.com/help/deeplearning/ug/design-time-series-narx-feedback-neural-networks.html>. [Último acceso: 1 11 2021].
- [22] I. M. Galván y J. M. Valls, «OPENCOURSEWARE REDES DE NEURONAS ARTIFICIALES,» Universidad Carlos III, Madrid.
- [23] B. Warsito, R. Santoso, Suparti y H. Yasin, «Cascade Forward Neural Network for Time Series Prediction,» *Journal of Physics*, vol. 1025, nº 012097, pp. 1-8, 2018.
- [24] S. Goyal y G. K. Goyal, «Cascade and Feedforward Backpropagation Artificial Neural Network Models For Prediction of Sensory Quality of Instant Coffee Flavoured Sterilized Drink,» *Canadian Journal on Artificial Intelligence, Machine Learning and Pattern Recognition*, vol. 2, nº 6, pp. 78-82, 2011.
- [25] S. Glen, «Levenberg-Marquardt Algorithm (Damped Least Squares),» Statistics How To, 2018. [En línea]. Available: <https://www.statisticshowto.com/levenberg-marquardt-algorithm/>. [Último acceso: 10 11 2021].
- [26] M. Kayri, «Predictive Abilities of Bayesian Regularization and Levenberg-Marquardt Algorithms in Artificial Neural Networks: A Comparative Empirical Study on Social Data,» *Mathematical and Computational Applications*, nº 21, pp. 1-11, 2016.
- [27] J. D. McCaffrey, «Neural Network Resilient Back-Propagation,» Wordpress, 2017. [En línea]. Available: <https://jamesmccaffrey.wordpress.com/2017/08/01/neural-network-resilient-back-propagation/>. [Último acceso: 2021 12 18].
- [28] F. R. Checa, «Reducción y clasificación de falsas alarmas en la uci utilizando árboles de decisión,» Universidad Rey Juan Carlos, Madrid, 2018.