



Trabajo final de máster

Redes Neuronales para la simulación de sistemas dinámicos en
aerogeneradores

Autor:

IÑAKI LARRAYOZ ARANO

Tutor:

ELKA RADOSLAVOVA KOROUTCHEVA

DEPARTAMENTO DE FÍSICA FUNDAMENTAL

02/07/2014

ÍNDICE

1 INTRODUCCIÓN.....	3
2 AEROGENERADORES.....	4
2.1 CLASIFICACIÓN DE AEROGENERADORES.....	4
2.2 ESTADO DEL ARTE: OBTENCIÓN DE CARGAS PARA EL DISEÑO DE UN AEROGENRADOR.....	5
2.3 DESCRIPCIÓN DEL AEROGENERADOR ESTUDIADO.....	9
2.3.1 TREN DE PONTENCIA.....	9
2.3.2 MULTIPLICADORA.....	10
2.3.3 FUENTES DE COMPORTAMIENTO NO LINEAL.....	11
2.3.3.1 Engranajes.....	11
2.3.3.2 Rodamientos.....	12
3 REDES NEURONALES.....	13
4 APLICACIÓN DE REDES NEURONALES EN LA MODELIZACIÓN DINÁMICA DEL TREN DE POTENCIA.....	19
4.1 PLANTEAMIENTO INICIAL Y ALCANCE.....	19
4.2 MODELO FÍSICO DINÁMICO.....	22
4.2.1 TÉCNICAS DE MODELIZACIÓN Y SOFTWARE ELEGIDO.....	22
4.2.2 DESCRIPCIÓN DEL MODELO.....	23
4.2.2.1 Tren de potencia.....	23
4.2.2.2 Eje principal	24
4.2.2.3 Multiplicadora.....	24
4.2.2.4 Controlador.....	26
4.2.3 SIMULACIONES.....	27
4.3 MODELO NEURONAL.....	34
4.3.1 TIPOLOGÍA DE RED	34
4.3.2 FUNCIONES DE TRANSFERENCIA.....	35
4.3.3 ARQUITECTURAS NURONALES.....	35
4.3.4 ENTRENAMIENTO.....	36
4.3.4.1 ALGORITMO DE ENTRENAMIENTO.....	36
4.3.4.2 PROCESO DE ENTRENAMIENTO.....	37
5 RESULTADOS.....	39
6 CONCLUSIONES.....	46
7 LINEAS DE INVESTIGACIÓN FUTURAS.....	48
8 REFERENCIAS.....	49

1 INTRODUCCIÓN

El presente trabajo final de máster tiene como objeto la aplicación de redes neuronales para la modelización dinámica de componentes mecánicos en aerogeneradores. Mediante esta técnica se pretende captar la dinámica de aquellos componentes que presentan un comportamiento no lineal cuyo modelado y simulación tiene un coste computacional tan alto, que únicamente los casos más críticos se estudian mediante técnicas convencionales de simulación dinámica en el dominio temporal durante la fase de diseño de detalle de un aerogenerador.

En este caso el estudio se centrará sobre el tren de potencia de un aerogenerador, que es el encargado de adecuar y transmitir la potencia recibida por el empuje aerodinámico del rotor al generador eléctrico, que es quien transformará la energía mecánica en energía eléctrica, el último fin de un aerogenerador.

El objetivo final de este modelado por medio de redes neuronales es el de partiendo de unos pocos datos, series temporales, que contengan los eventos más característicos de la dinámica del componente a estudiar, poder extrapolar un modelo dinámico no lineal que sea representativo para el resto de casos a estudiar durante las fases de diseño. En la actualidad para estos estudios se utilizan modelizaciones muy detalladas para los casos más críticos, y otras modelizaciones muy simplificadas para el resto de modelos dinámicos durante la fase de extracción de cargas. Estos modelos simplificados son lineales en lo que tren de potencia se refiere, y dado el alto grado de no linealidad del sistema, en ocasiones hace que las cargas obtenidas no sean del todo representativas.

El último fin, es por tanto, utilizando la información obtenida de los modelos detallados, obtener un modelo neuronal, que con un coste computacional muy bajo, pueda aplicarse a toda la casuística de casos de carga utilizada durante la fase de diseño de un aerogenerador, para poder obtener unas cargas de componente que contemplen las no linealidades del sistema y por tanto se asemejen lo máximo posible a la realidad.

Ha de mencionarse que al tratarse de un trabajo fin de máster, donde el alcance es limitado y dado que la casuística a abordar es muy amplia, el alcance se ha acotado en pos de poder obtener ciertos resultados durante el desarrollo del presente trabajo.

Para este estudio el planteamiento es el siguiente:

- Seleccionar aquellos eventos representativos de la dinámica del tren de potencia.
- Realizar simulaciones detalladas de estos eventos.
- Con los datos de las simulaciones, estudiar redes neuronales para captar la dinámica del sistema.
- Validar los resultados que ofrece la red para un nuevo caso de carga frente a los resultados obtenidos de la simulación detallada del mismo caso de carga.

Por último se plantearán las conclusiones obtenidas así como las posibles futuras vías de desarrollo.

Destacar que el presente trabajo pretende abrir una línea de investigación en un ámbito de aplicación de las redes neuronales que parece prometedor y no establecer ninguna conclusión dogmática al respecto ya que los medios disponibles hace que ciertas asunciones tomadas a la hora de realizar las simulaciones no estén a la altura del estado del arte actual. No por ello los resultados dejan de ser representativos de la potencialidad de la técnica.

2 AEROGENERADORES

Los aerogeneradores son máquinas que por medio de una fuente de energía renovable como es el viento obtienen energía eléctrica. Dentro de este tipo de máquinas tenemos una gran variedad dependiendo de diferentes factores, como el ámbito de aplicación, la tipología, o la tecnología empleada.

En este apartado en primer lugar realizaremos una pequeña clasificación de aerogeneradores a modo introductorio, para después describir el estado del arte actual en lo que a obtención de cargas dimensionantes de un aerogenerador se refiere. Por último se hará una descripción a nivel mecánico de la máquina que tenemos como estudio.

2.1 CLASIFICACIÓN DE AEROGENERADORES

Como primera clasificación podemos utilizar el ámbito de aplicación o escala. Diferenciamos entre aquellas turbinas orientadas a la pequeña producción energética, pensadas para pequeños consumos, en las que la energía generada habitualmente se almacena en baterías para su posterior utilización en el ámbito doméstico.

Por otro lado tenemos aquellas turbinas de mayor escala pensadas para la producción energética en masa, que proporcionan energía eléctrica a las redes de suministro. La turbina estudiada en el presente trabajo corresponde a este último grupo.

En lo que a tipología se refiere podemos hacer otra gran división en función de la posición del eje de giro de la máquina, tenemos dos. Las máquinas de eje vertical constan de un mástil alrededor del cual se colocan los perfiles aerodinámicos que extraen la energía del viento. Una de sus principales ventajas son una mayor simplicidad, ya que no necesitan orientarse respecto al viento incidente y toda la maquinaria asociada a la producción energética está situada en el suelo, por lo que los costes de este tipo de máquina son menores. La principal desventaja reside en la menor eficiencia y la menor escala de estos, por lo que su ámbito de aplicación suele reducirse a pequeñas producciones energéticas.

El otro tipo, son aquellas máquinas cuyo eje de giro está situado en posición horizontal. Son las más habituales en la industria energética a gran escala. Su principal ventaja frente a otros diseños son su mayor eficiencia en la producción energética, mientras la complejidad técnica aumenta ya que la máquina tiene que orientarse, así como regular su potencia. Sus costes son más elevados debido a que toda la maquinaria involucrada en la producción energética se sitúa sobre la torre, aumentando mucho los costes de esta última. La máquina que tenemos como estudio pertenece a este último grupo.



*Ilustración 1:
Aerogenerador
estudiado.*

Dentro de los aerogeneradores de eje horizontal dos tecnologías son principalmente las utilizadas en los trenes de potencia.

La primera de ellas es conocida como *Direct Drive*, en la que el rotor de la máquina está directamente unido a un generador multi-polo. Ayudado por la electrónica de potencia la energía mecánica se convierte en una energía eléctrica apta para ser inyectada en la red eléctrica.

La segunda se conoce como el concepto con multiplicadora, en el que la velocidad de giro del rotor se multiplica por medio de una multiplicadora mecánica haciendo posible que por medio de un generador más sencillo se pueda generar energía apta para ser inyectada en la red eléctrica.

El aerogenerador que tenemos como estudio corresponde a esta segunda tipología.

2.2 ESTADO DEL ARTE: OBTENCIÓN DE CARGAS PARA EL DISEÑO DE UN AEROGENERADOR

En el presente apartado se mostrarán a grandes rasgos las etapas habituales dentro del proceso de obtención de cargas mecánicas para el posterior dimensionamiento de los componentes de un aerogenerador. Esta descripción, aparte de servir como introducción para los capítulos posteriores, pretende expresar la motivación de este trabajo.

Las cargas mecánicas principales que recibe una turbina de viento provienen de cargas aerodinámicas como bien cabría esperar. Para determinar estas cargas por un lado tenemos campañas de medición de viento durante un periodo de tiempo determinado en el emplazamiento donde la turbina será instalada. Obtenidas las mediciones se calculan distribuciones estadísticas y parámetros característicos con objeto de caracterizar el viento en nuestro emplazamiento.

Por otro lado existen normativas que regulan la generación de los casos de carga que dimensionarán nuestro aerogenerador. Se llama caso de carga a un evento temporal durante el que el aerogenerador trabajará en ciertas condiciones representativas a lo largo de su vida.

Estos casos de carga se pueden agrupar en dos conjuntos, los casos de carga extremos y los casos de carga de fatiga. Estos están estrechamente relacionados con los dos modos de fallo principales de los componentes mecánicos.

- **Caso de carga de extrema:** Son casos en los que la máquina sufre cargas límite, frente a las cuales el objetivo principal es el de garantizar la integridad de la misma.
- **Casos de fatiga:** Son aquellos que generan fatiga mecánica en la máquina. Se llama fatiga a un fenómeno por el cual la rotura de los materiales bajo cargas dinámicas cíclicas se produce más fácilmente que con cargas estáticas. Son cargas que siendo de magnitud inferior a las extremas, por el hecho de ser repetitivas a lo largo de la vida de la máquina van mellando los componentes hasta producir su rotura en el peor de los casos.

Una de las normativas que regula en la actualidad la generación de casos de carga es la IEC 61400-1 [1].

Los casos de carga que se presentan en esta normativa son los siguientes:

Design situation	DL C	Wind condition	Other conditions	Type of analysis	Partial safety factors
1) Power production	1.1	NTM $V_{in} < V_{hub} < V_{out}$	For extrapolation of extreme events	U	N
	1.2	NTM $V_{in} < V_{hub} < V_{out}$		F	*
	1.3	ETM $V_{in} < V_{hub} < V_{out}$		U	N
	1.4	ECD $V_{hub} = V_r - 2 \text{ m/s}, V_r, V_r + 2 \text{ m/s}$		U	N
	1.5	EWS $V_{in} < V_{hub} < V_{out}$		U	N
2) Power production plus occurrence of fault	2.1	NTM $V_{in} < V_{hub} < V_{out}$	Control system fault or loss of electrical network	U	N
	2.2	NTM $V_{in} < V_{hub} < V_{out}$	Protection system or preceding internal electrical fault	U	A
	2.3	EOG $V_{hub} = V_r \pm 2 \text{ m/s}$ and V_{out}	External or internal electrical fault including loss of electrical network	U	A
	2.4	NTM $V_{in} < V_{hub} < V_{out}$	Control, protection, or electrical system faults including loss of electrical network	F	*
3) Start up	3.1	NWP $V_{in} < V_{hub} < V_{out}$		F	*
	3.2	EOG $V_{hub} = V_{in}, V_r \pm 2 \text{ m/s}$ and V_{out}		U	N
	3.3	EDC $V_{hub} = V_{in}, V_r \pm 2 \text{ m/s}$ and V_{out}		U	N
4) Normal shut down	4.1	NWP $V_{in} < V_{hub} < V_{out}$		F	*
	4.2	EOG $V_{hub} = V_r \pm 2 \text{ m/s}$ and V_{out}		U	N
5) Emergency shut down	5.1	NTM $V_{hub} = V_r \pm 2 \text{ m/s}$ and V_{out}		U	N
6) Parked (standing still or idling)	6.1	EWM 50-year recurrence period		U	N
	6.2	EWM 50-year recurrence period	Loss of electrical network connection	U	A
	6.3	EWM 1-year recurrence period	Extreme yaw misalignment	U	N
	6.4	NTM $V_{hub} < 0,7 V_{ref}$		F	*
7) Parked and fault conditions	7.1	EWM 1-year recurrence period		U	A
8) Transport, assembly, maintenance and repair	8.1	NTM V_{maint} to be stated by the manufacturer		U	T
	8.2	EWM 1-year recurrence period		U	A

Tabla 1: Casos de carga de la normativa IEC61400-1

Donde:

Wind conditions o condiciones de viento:

NTM: Normal turbulence model o modelo de turbulencia normal.

ETM: Extreme trubulence model o modelo de turbulencia extremo.

ECD: Extreme coherent gust with direction change o racha extrema coherente con un cambio de dirección de viento.

EDC: Extreme direction change o cambio de dirección de viento extremo.

EWS: Extreme wind shear o viento cortante extremo.

EOG: Extreme operating gust o racha de viento extrema.

NWP: Normal wind profile o perfil de viento normal.

EWM: Extreme wind speed o velocidad de viento extremo.

Type of analysis:

U: Ultimate o extrema.

F: Fatiga

Partial safety factores o factores de seguridad parcial:

N: Normal.

A: Anormal.

T: Transporte

Con las mediciones de viento realizadas y aplicada la normativa, los casos de carga estarán definidos, es decir caracterizadas las cargas de viento y el estado de operación de nuestra máquina.

La siguiente fase corresponde a una simulación aeroelástica del aerogenerador con todos los casos de carga definidos. Estas simulaciones están basadas en la teoría BEM, en la que el principal objetivo es traducir los casos de carga definidos previamente en cargas aerodinámicas en las palas y por lo tanto en cargas mecánicas en el aerogenerador. Para ello se utilizan modelos donde la parte aerodinámica, las palas principalmente, se representa con gran detalle, pero otras partes menos importantes en estas fases, como podría ser el tren de potencia, se representa por medio de un sistema simplificado tipo muelle-amortiguador. Esta modelización del tren de potencia se hace insuficiente en muchos casos para el diseño en detalle debido a la no linealidad de los componentes.

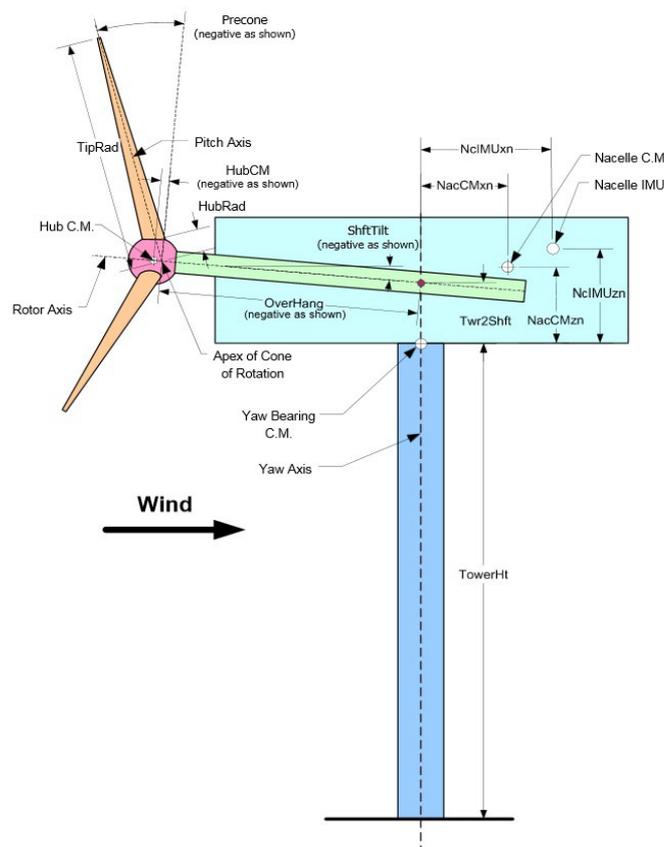


Ilustración 2: Modelo Aeroelástico[2]

La utilización de estos modelos más simplificados de ciertos componentes se debe al gran número de casos de carga que impone la normativa, que en total son en torno a 120 para los casos de fatiga y alrededor de 1000 para los casos de extrema. La utilización de modelos más detallados para los componentes no aerodinámicos haría crecer el coste de computación de tal forma que el problema se volvería inabordable.

Este tipo de modelo hace que el detalle de las cargas obtenidas en ciertos componentes como pudiera ser el tren de potencia no sea suficiente. Para ello se utilizan modelos detallados en los que todos los componentes mecánicos que intervienen en la transmisión de potencia son representados. La principal ventaja de este tipo de modelización es la capacidad de captar todas las no linealidades del sistema y por tanto la obtención de cargas que se asemejan a las que realmente sufrirán los componentes. La desventaja principal es que nuevamente debido a la complejidad de los modelos el coste de computación hace que únicamente unos pocos casos de carga, aquellos que se consideran más críticos, puedan ser evaluados por medio de estas técnicas.

Para una correcta caracterización de las cargas y por tanto dimensionado de los componentes es necesario conocer:

- Cargas extremas: Máximas cargas que sufrirán los componentes.
- Cargas de fatiga: Cargas que durante los eventos normales de funcionamiento de la máquina sufrirán los componentes.

El actual estado del arte hace que la obtención de cargas extremas para los casos más críticos sea viable por medio de las simulaciones detalladas, pero abordar todos los casos de carga de extrema y fatiga mediante estas técnicas no es posible. A su vez las cargas obtenidas por medio de simulaciones simplificadas, hace que las cargas no sean del todo representativas.

El presente trabajo fin de máster presenta una posible vía de solución de esta problemática por medio de la utilización de redes neuronales. El planteamiento es el siguiente:

Utilizando las salidas de carga obtenidas de las simulaciones detalladas y teniendo como entrada variables accesibles en ambas simulaciones, simples y detalladas, utilizar una red neuronal para captar la dinámica no lineal del sistema complejo y tomando las entradas del modelo simple en otros casos de carga, generar salidas con la dinámica interna que mostraría el modelo detallado.

Esta solución nos permitiría por medio de la red neuronal abordar la totalidad de casos de carga captando la dinámica no lineal interna, utilizando modelos simplificados, sin apenas costes de computación añadidos, pudiendo así obtener cargas lo más cercanas posibles a la realidad que nos permitan realizar un diseño óptimo de los componentes mecánicos.

2.3 DESCRIPCIÓN DEL AEROGENERADOR ESTUDIADO

Basándonos en las clasificaciones anteriores estaríamos frente una máquina de gran escala, de eje horizontal con tres palas y un tren de potencia con multiplicadora. En los siguientes apartados se realizará una breve descripción del sistema mecánico. Los datos utilizados para la modelización son datos genéricos que corresponden a una turbina de 2MW de potencia.

2.3.1 Tren de potencia

Centrándonos en el tren de potencia, se ha utilizado la configuración clásica en los aerogeneradores modernos: eje principal, multiplicadora, acoplamiento flexible y generador.

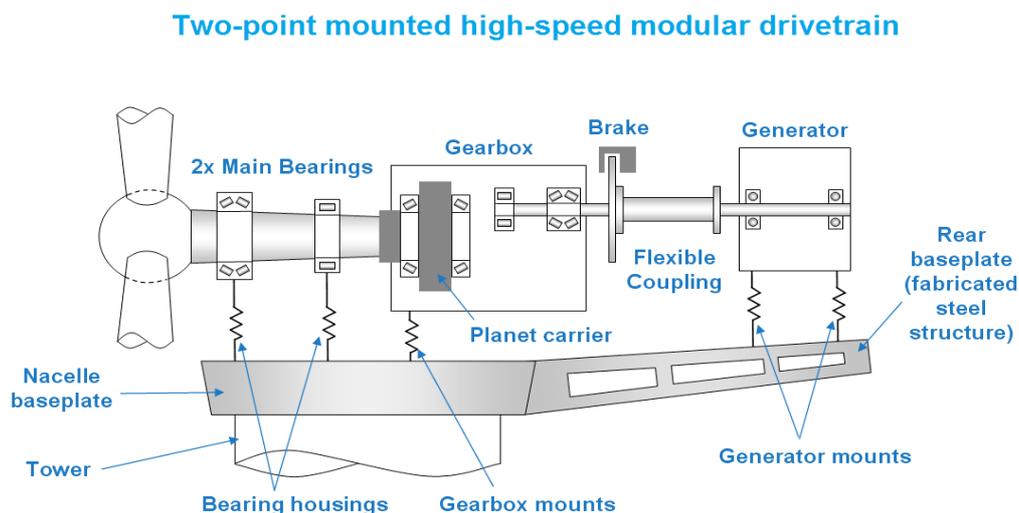


Ilustración 3: Tren de potencia clásico.

Los componentes principales de este tren de potencia son:

- **Eje principal soportado por dos rodamientos:** Son los encargados de soportar las cargas provenientes del rotor y transmitir las al bastidor, así como los encargados de transmitir el par torsor, que será el encargado de generar la potencia eléctrica.
- **Multiplicadora (*Gearbox*):** Se encarga de aumentar la velocidad de giro del rotor, en torno a 10-15 rpm, a velocidades de giro aptas para la generación eléctrica alterna, en torno a 1500 rpm. Esta multiplicación se realiza por medio de engranajes que están soportados por rodamientos. El estudio se centrará sobre los rodamientos de la multiplicadora.
- **Freno (*Brake*):** Es el responsable de detener el giro de la máquina.
- **Acoplamiento flexible (*Flexible coupling*):** Absorbe los desalineamientos que hay entre el eje de salida de la multiplicadora y el generador.
- **Generador (*Generator*):** Es el encargado de transformar la energía de rotación en energía eléctrica.

A continuación se explicará el funcionamiento interno de una multiplicadora, para entender su funcionamiento y el porqué de su comportamiento no lineal.

2.3.2 Multiplicadora

La multiplicadora está formada por un conjunto de engranajes, ejes y rodamientos que transmiten la potencia entre el eje de entrada y salida, aumentando la velocidad de giro a costa de reducir el par. La potencia, el producto par por velocidad, permanece constante si obviamos las pérdidas mecánicas por fricción. Las multiplicadoras habitualmente tienen un ratio de transmisión fijo, en nuestro caso en torno a 100, esto quiere decir que la velocidad de giro se aumentará en cien mientras que el par se reducirá en la misma proporción, según la regla mencionada.

La multiplicadora que tenemos en este estudio está compuesta por una etapa planetaria inicial, dos etapas paralelas consecutivas y dos brazos de reacción.



Ilustración 4: Multiplicadora de aerogenerador.

La entrada de potencia se realiza a través de la etapa planetaria. Está por medio del giro del porta planetas, y consecuentemente de los planetas, que se reaccionan en la corona que es estática, transmiten el giro a través del solar aplicando un ratio de multiplicación. Este giro del solar es transmitido a la primera etapa paralela por medio de un par de engranajes situados en dos ejes, y este a su vez por otro par de engranajes a la etapa de salida.

Todo los elementos rodantes mencionados hasta ahora, porta planetas, planetas y ejes, a excepción del solar, están soportados por rodamientos.

Para estudios preliminares se puede considerar que los elementos mecánicos mencionados se comportan de forma lineal, pero cuando se requiere un cálculo detallado de las cargas que ven cada uno de los componentes, la consideración de los comportamientos no lineales que se describen a continuación es fundamental.

Estos componentes dado su carácter rotatorio, y las velocidades de giro, 10 rpm en la etapa de entrada y aproximadamente 1500 en la de salida, hace que el número de ciclos de carga que vean sea muy elevado. Por lo que la caracterización de las cargas a fatiga se hace fundamental para un correcto dimensionamiento de estos, más teniendo en cuenta que para un número de ciclos de carga dado, el daño producido es exponencial respecto del nivel de carga.

2.3.3 FUENTES DE COMPORTAMIENTO NO LINEAL

Las no linealidades dentro de la multiplicadora las podemos encontrar tanto en engranajes como en rodamientos, ya que el principio de funcionamiento de estos está basado en los contactos. Los contactos son una clase de problemas no lineales que están relacionados con la naturaleza cambiante de las condiciones de contorno de las estructuras que intervienen durante el movimiento. Habitualmente el problema de los contactos se representa mediante una discontinuidad.

2.3.3.1 Engranajes

Son los encargados de la transmisión de potencia, así como los encargados de por medio de combinaciones de números de dientes, generar un ratio de multiplicación.

Los pares de engranes son dos ruedas dentadas que transmiten potencia mecánica por medio del giro. Estas están formadas por dientes que contactan y dejan de contactar conforme giran. Además en muchas ocasiones varios dientes están en contacto a la vez. Estos dos factores hacen que la rigidez del conjunto no sea continua, siendo esa variación de rigidez la primera fuente de auto excitación del sistema. Esta es una de las no linealidades del sistema.

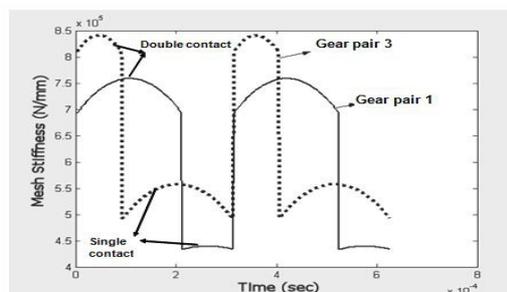


Ilustración 5: Variación de la rigidez de engrane a lo largo del giro [3].

Además los engranajes tienen un juego interno que hace que el contacto no siempre sea continuo, sobre todo cuando tenemos cargas fluctuantes o inversiones en la dirección del par aplicado. Esta holgura es una no linealidad de tipo contacto, además de una fuente de impactos.

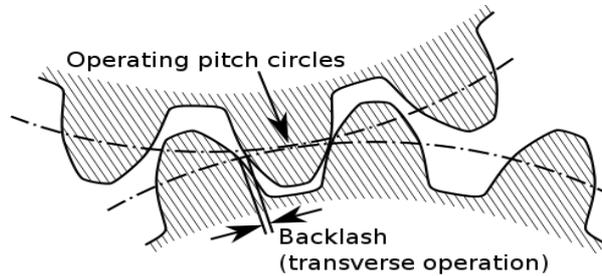


Ilustración 6: Backlash o juego interno en engranajes.

2.3.3.2 Rodamientos

Los rodamientos son los componentes mecánicos encargados de garantizar el giro de los componentes rotativos con un bajo coeficiente de fricción, así como los encargados de transmitir las cargas no útiles generadas, en los engranajes en este caso, al cuerpo de la multiplicadora que es donde se reaccionan.

Estos están formados por cuerpos rodantes, bolas o rodillos, que giran entre dos anillos permitiendo el giro relativo de estos. Durante este proceso el número de rodillos que están en contacto varía en función del giro y en función de las cargas que el rodamiento recibe varía el contacto entre rodillos y anillos. Estos dos factores hacen que la rigidez que estos componentes tienen varíe de forma no lineal.



Ilustración 7: Rodamiento

Al igual que ocurría en los engranajes, los componentes internos del rodamiento presentan juegos, por tanto un comportamiento no lineal.

Una vez realizada una breve introducción acerca del sistema a estudiar, se realizará otra breve introducción sobre redes neuronales.

3 REDES NEURONALES

Existen algunos problemas en el campo de la ingeniería, para los cuales la búsqueda de una solución exacta requiere una cantidad de recursos prácticamente imposibles, y por lo cual, sólo se encuentra en la práctica una solución aceptable. Las redes neuronales artificiales, o ANN [4] (Artificial Neural Networks), pueden ofrecer buenas soluciones a esa clase de problemas. Entre sus aplicaciones industriales más comunes se encuentran: identificación y modelado, optimización, clasificación, control de procesos y reconocimiento de patrones [5].

Las redes neuronales tienen su origen en la simulación abstracta de los sistemas nerviosos biológicos. La primera red neuronal fue propuesta en 1943 por McCulloch y Pitts [6], en términos de un modelo computacional de "actividad nerviosa", que consistía en un modelo binario formado por un conjunto de unidades llamadas "neuronas" conectadas entre sí, en el cual cada neurona tiene un umbral preestablecido. Tales conexiones tienen una gran semejanza con las *dendritas* y los *axones* de los sistemas nerviosos biológicos, representados en la ilustración inferior (b). Este primer modelo sirvió de ejemplo para los modelos posteriores de Hebb [7], quien propuso un mecanismo de aprendizaje de las neuronas. Rosenblatt [8], realizó la primera aplicación práctica a principios de la década de los 50, y aproximadamente al mismo tiempo, propusieron un nuevo algoritmo de entrenamiento de ANN, denominado regla Widrow-Hoff, que se sigue utilizando en la actualidad. Por otra parte, Minsky [9] advirtió de las limitaciones de los modelos de Rosenblatt y Widrow para el entrenamiento de redes complejas, e influenciaron a otros investigadores a desarrollar nuevas teorías. En este sentido, Kohonen [10] propuso una matriz de correlación para la memoria asociativa, Grossberg [11] desarrolló nuevas teorías de Redes Auto organizadas, formulando las bases de la Teoría de la Resonancia Adaptativa (ART), y Hopfield [12] propuso las redes recurrentes.

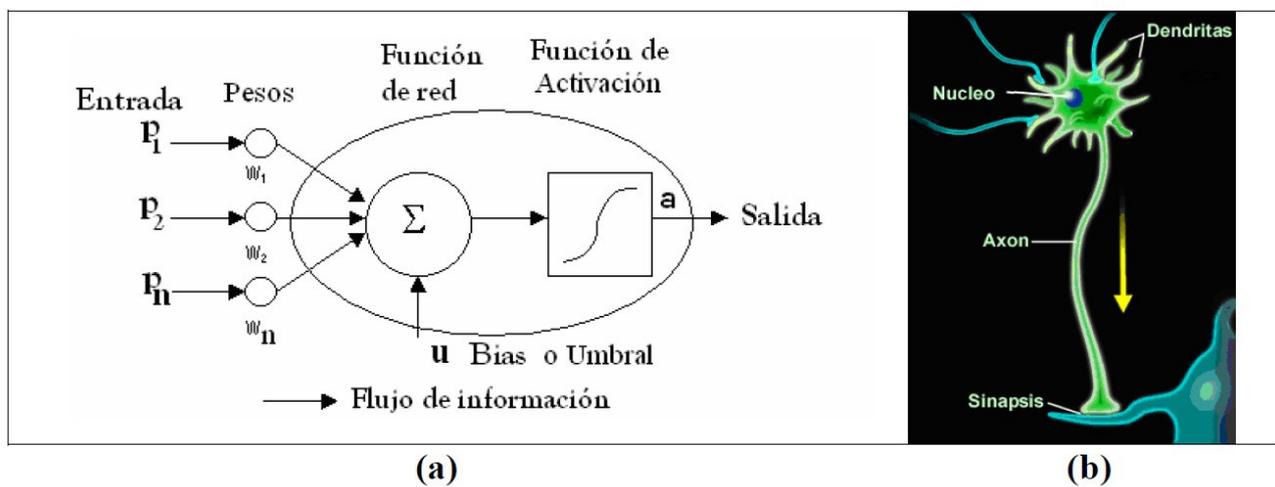


Ilustración 8: (a) Red neuronal. (b) Representación biológica de una neurona

Las partes fundamentales de una neurona artificial básica que se observan en la figura son:

- **Entrada:** Es el vector que excita a la neurona. Se compone de aquellos datos más representativos (patrones) del fenómeno al que se desea aplicar una ANN.

- **Pesos:** Son valores que se asocian a cada una de las conexiones entre neuronas de una red. La variación de éstos determina el aprendizaje de una red.
- **Función de activación:** Se encarga de calcular el nivel o estado de activación de la neurona en función de la entrada total. Es quizás la característica principal de las neuronas, la que mejor define el comportamiento de la misma. En distintos modelos de ANN, han sido propuestas diferentes funciones de activación. Las más populares están presentes en la siguiente tabla.

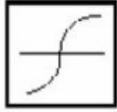
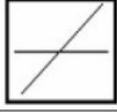
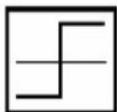
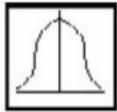
Funciones de transferencia	Fórmula	Representación Gráfica
Sigmoide Logarítmico	$f(n) = \frac{1}{1 + e^{-n}}$	
Sigmoide de Tangente Hiperbólica	$f(n) = \frac{e^n - e^{-n}}{e^n + e^{-n}}$	
Lineal	$f(n) = n$	
Escalón	$f(n) = \begin{cases} 1 & n \geq 0 \\ 0 & n < 0 \end{cases}$	
Escalón Simétrico	$f(n) = \begin{cases} 1 & n \geq 0 \\ -1 & n < 0 \end{cases}$	
Base Radial Gaussiana [⊗]	$f(n) = \exp\left[-\ n - c\ ^2 / d\right]$	
Competitiva	$f(n) = \begin{cases} 1 & \text{neurona con } \max(n) \\ 0 & \text{todas las demás neuronas} \end{cases}$	-

Tabla 2: Funciones de transferencia más comunes [13].

- **Función de red o de propagación:** Calcula el valor de base o entrada total a la unidad. Equivale a la combinación de las señales que excitan o inhiben a las neuronas biológicas. Las funciones de red más utilizadas se presentan en la anterior tabla. La función lineal transmite la entrada (p) a través de una conexión, multiplicándola por su peso correspondiente (w), formando el producto pw , que también es un escalar. Luego, a este producto se le añade otro elemento constitutivo, denominado bias o umbral (u), para completar la suma ($wp+u$), que será el argumento de la función de activación (f), la cual produce la salida escalar a . De tal apreciación, se deriva la siguiente ecuación:

$$a = f\left(\sum_{j=1}^n w_j p_j + u\right) \tag{3.1}$$

Donde j es cada uno de los componentes del vector de entrada.

Funciones de red	Comentarios	Fórmula
Lineal (con bias)	Función de red mas utilizada	$n = \sum_{j=1}^R w_j p_j + b$
De segundo orden	n_i es una combinación lineal de polinomios de orden superior de la variable de entrada	$n = \sum_{j=1}^R \sum_{k=1}^R w_{jk} p_j p_k + b$
Delta ($\Sigma - \Pi$)	Poco común	$n = \prod_{j=1}^R w_j p_j$

Tabla 3: Funciones de red

- **Salida:** Es el valor de salida de la neurona en función de la activación de la misma. En el caso de la utilización de una ANN para el proceso de diagnóstico de fallos, la salida equivale al diagnóstico de la red. Las ANN básicas tienen al menos tres capas de neuronas: una capa de entrada, una o más capas ocultas, y una capa de salida, como se muestra en la figura 9. Cada capa de la ANN contiene un grupo de unidades de procesamiento, llamadas nodos o neuronas, que envían su propia salida a todos los nodos de la capa siguiente de manera unidireccional.

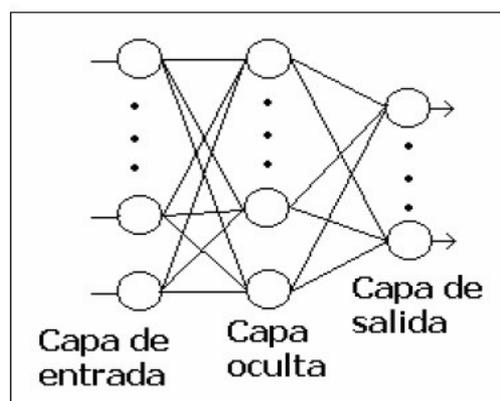


Ilustración 9: Arquitectura de red neuronal

Las neuronas de la capa de entrada reciben las señales externas, y sirven de interfaz entre esta información del mundo exterior y las unidades de proceso internas (neuronas de la capa oculta) de

la ANN, completando un proceso análogo a algunas partes del cuerpo humano, como ojos o dedos. De manera similar, la capa de salida de la ANN, sirve como una interfaz entre las unidades internas de la red y el mundo exterior.

Por otra parte, existen dos fases en la utilización de una ANN convencional: la fase de **aprendizaje** o **entrenamiento** y la fase de **prueba**. Una porción de la información de entrada se utiliza para entrenar la red, mientras que la otra porción restante, es utilizada para la fase de prueba.

Las ANN son sistemas de aprendizaje basados en ejemplos. La fase de **aprendizaje** consiste en una adaptación progresiva de los valores internos de la red, hasta obtener el comportamiento deseado. La capacidad de una red para resolver un problema está ligada de forma fundamental al tipo de ejemplos disponible en el proceso de aprendizaje, que se introducen paulatinamente para modificar el valor de los pesos en todas las conexiones con un determinado algoritmo, hasta conseguir un error dentro de los márgenes del diseño. La red efectúa este proceso de manera cíclica, comparando la salida real de la red (y_i), con la salida esperada (s_i). Matemáticamente, el objetivo de la fase de entrenamiento es minimizar el error para todas las neuronas de salida de la red, y todos los datos de entrenamiento. Tomando como referencia el error cuadrático medio (MSE), su cálculo puede plantearse como la ecuación (3.2).

$$MSE = \frac{1}{N} \sum_{i=1}^{n_c} (s_i(n) - y_i(n))^2 \quad (3.2)$$

Donde:

N : Es el número de datos de entrenamiento

n_c : Es el número de neuronas de la capa de salida

y_i : Es la predicción de la i -ésima neurona de la capa de salida, para un dato de entrenamiento n .

s_i : Es el valor objetivo de la i -ésima neurona de la capa de salida, para un dato de entrenamiento n .

La modificación de los pesos se basa en el algoritmo seleccionado para realizar el entrenamiento, que varía según el tipo de red utilizada, y puede hacerse posterior a la introducción de cada ejemplo del conjunto, o una vez introducidos todos ellos. Para minimizar el valor del error, se afronta el problema a través de la variación de la matriz de pesos y umbrales, es decir, construyendo un algoritmo que permita a la red ajustar sus unidades de proceso interno (pesos y umbrales), de acuerdo al error que se produce en las neuronas de la capa de salida. Por lo general, esos valores se hallan con algoritmos que adoptan la formulación iterativa dada por la ecuación (3.3):

$$W(n+1) = W(n) + \Delta W(n) \quad (3.3)$$

En donde:

$W(n)$: Es el valor del peso particular para el patrón de entrada n .

$W(n+1)$: Es el valor del peso particular para el patrón de entrada $n+1$.

$\Delta W(n)$: Es el ajuste del valor del peso, para el patrón de entrada n .

Las bias o umbrales, también requieren un ajuste progresivo, que se indica en la ecuación (3.4):

$$u(n+1) = u(n) + \Delta u(n) \quad (3.4)$$

En donde:

$u(n)$: Es el valor del umbral particular para el patrón de entrada n .

$u(n+1)$: Es el valor del umbral particular para el patrón de entrada $n+1$.

$\Delta u(n)$: Es el ajuste del umbral del peso, para el patrón de entrada n .

Dependiendo del problema a resolver, se pueden distinguir tres tipos de aprendizaje:

En el *Aprendizaje supervisado* se conocen los datos del conjunto de aprendizaje y la información relativa a la solución del sistema. Para este tipo de aprendizaje, se dice que hay un profesor externo encargado de determinar si la red se está comportando de forma adecuada, mediante la comparación entre la salida producida y la esperada, y de actuar en consecuencia modificando apropiadamente los valores de los pesos.

Para el *Aprendizaje no supervisado* no existe profesor externo que determine el aprendizaje. La red modificará los valores de los pesos a partir de información interna, y tratará de determinar las características significativas de los datos del conjunto de entrenamiento. A este tipo de modelos se les conoce también como sistemas auto organizados, ya que la red se ajusta sólo a valores recibidos como entrada. Existen numerosas ANN que trabajan con este tipo de aprendizaje, entre ellas, los Mapas Auto organizados (SOM), las redes de Hopfield [12], Kohonen [10] y las ART [11]. Este tipo de aprendizaje, posee una variante denominada *Aprendizaje por refuerzo*, en la que no se dispone de información concreta sobre el error cometido por la red para cada ejemplo de aprendizaje, sino que simplemente se determina si la salida producida para dicho patrón es adecuada o no.

Las redes neuronales gozan de características que las hacen muy interesantes en el modelado de sistemas dinámicos, como la capacidad de aproximar funciones no lineales con precisiones arbitrariamente pequeñas. Las ventajas principales son:

- Son modelos no lineales, puesto que la función de transferencia es no lineal.
- Son dinámicos si se incluyen conexiones recurrentes o estáticas si no las incluyen.
- Son modelos paramétricos y los parámetros corresponde a los pesos de las conexiones entre neuronas.
- Son modelos adaptativos, puesto que la aparición de nuevos datos permite el reaprendizaje de los parámetros adaptando los valores anteriores a los datos actuales.
- Son tolerantes a fallos, ya que su comportamiento está distribuido entre todos los parámetros. Así cuando uno de ellos es incorrecto, el resultado global degrada pero no deja al modelo inoperativo.
- Son inherentemente paralelos permitiendo una implementación eficiente lo que las convierte en aptas para la computación en tiempo real.

Por otra a parte los modelos neuronales tienen inconvenientes entre los que sobresalen:

- Son poco explicativos respecto a los principios físicos que rigen la dinámica del sistema identificado.
- La posibilidad de incorporar información previa al modelo es muy limitada, cuando no nula.

4 APLICACIÓN DE REDES NEURONALES EN LA MODELIZACIÓN DINÁMICA DEL TREN DE POTENCIA

En el siguiente apartado se desarrollará el planteamiento inicial del proyecto, en el que por medio de redes neuronales se pretende captar la dinámica no lineal de un componente de aerogenerador como es una multiplicadora, partiendo de datos obtenidos por la simulación detallada de todo el tren de potencia.

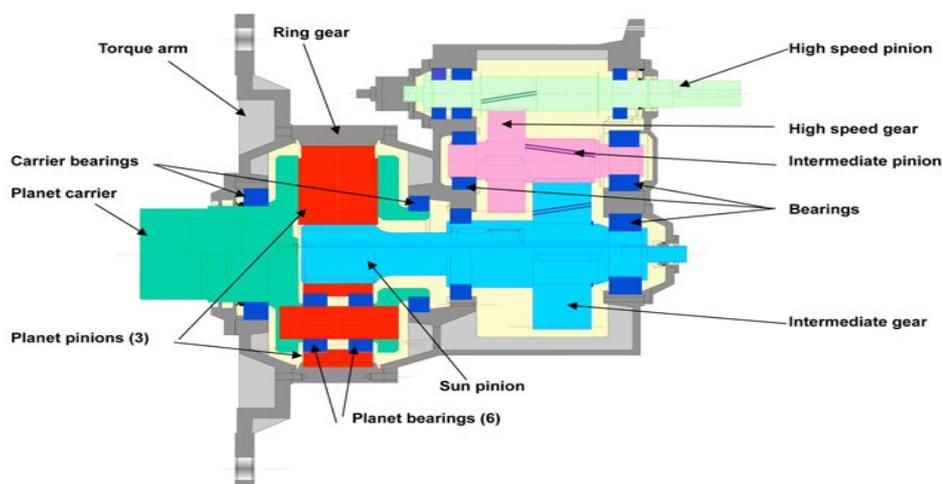
4.1 PLANTEAMIENTO INICIAL Y ALCANCE

Como ya se ha mencionado en el apartado de descripción del sistema, una multiplicadora está compuesta principalmente por un porta planetas, engranajes, ejes y rodamientos. Estos últimos son quienes en última instancia reaccionan todos los esfuerzos no útiles que se dan durante la transmisión de potencia, a excepción del par torsor, el único esfuerzo útil durante la generación eléctrica. Dado que son los últimos en la cadena de reacción de esfuerzos, con los comportamientos no lineales que hemos mencionado, hace que la caracterización de las cargas de estos requiera de simulaciones detalladas. A su vez este es uno de los puntos de más interés a la hora de dimensionar una multiplicadora y garantizar su integridad durante todo su ciclo de vida, además de ser los componentes que más fallos presentan en las multiplicadoras.

Por estos motivos la modelización dinámica del tren de potencia mediante redes neuronales se centrará en la obtención de cargas en rodamientos, utilizando las redes para captar su dinámica.

La multiplicadora sobre la que se ha realizado el estudio tiene:

- Un porta planetas soportado por dos rodamientos (*carrier bearings*).
- Tres planetas soportados por dos rodamientos cada uno. (*planet bearings*).
- Un eje lento (*low speed shaft*) soportado por dos rodamientos.
- Un eje intermedio (*intermediate speed shaft*) soportado por dos rodamientos.
- Un eje rápido (*high speed shaft*) soportado por tres rodamientos.



En primera instancia el presente estudio pretendía captar la dinámica de todos los rodamientos de la multiplicadora por medio de redes neuronales, pero dado el comportamiento particular que presenta cada uno de ellos y el tiempo necesario para la selección de arquitecturas y entrenamiento de redes, quedaba fuera del alcance de un proyecto final de máster. Por ello se seleccionó un rodamiento en particular para acometer el estudio, uno de los rodamientos de la etapa de salida de la multiplicadora.

Hasta el momento se ha descrito nuestro sistema, su estructura, sus componentes, así como las particularidades de comportamiento que caracterizan el comportamiento pasivo o natural del sistema sin mencionar el sistema de control del aerogenerador. Este es el encargado de actuar y controlar el comportamiento del aerogenerador y en lo que nos atañe es quien regulará la entrada de potencia por el rotor, por medio de la actuación de sistema de pitch y el encargado de regular la potencia de salida por parte del generador. Es tal su importancia que junto con los casos de viento que se mencionaron en el apartado anterior es el responsable de las cargas que ve nuestro tren de potencia y por tanto de la dinámica forzada. Se ha constatado la criticidad de este sistema como se expondrá en las conclusiones.

Como ya se mencionó, la simulación detallada del tren de potencia se utiliza en aquellos casos en los que la dinámica no lineal del sistema se hace más relevante y uno de los actores principales es el control ya que es quien regula estos eventos. Los eventos que a día de hoy se consideran dimensionantes de una multiplicadora, a nivel dinámico son los siguientes y por tanto los que se considerarán para el estudio:

- **Arranque:** Durante el arranque el aerogenerador comienza a girar libremente sin recibir reacción alguna por parte del generador. El sistema de control comienza a introducir par en el rotor por medio de actuar el sistema de pitch, variando el ángulo de ataque de las palas, y el tren de potencia comienza a adquirir velocidad. Cuando esta alcanza cierto valor el generador se conecta y comienza la generación eléctrica. Esta conexión es similar a un impacto y genera una sobre oscilación a lo largo del tren de potencia y por tanto un pico de carga.
- **Pérdida de red eléctrica:** Un evento habitual durante la generación eléctrica en aerogeneradores suele ser la pérdida de conexión eléctrica. Esto hace que en cierto instante de tiempo la reacción que hace el generador desaparezca y pasado un tiempo, cuando la conexión se restablece vuelve a conectarse violentamente. Esto hace que tengamos una carga y descarga con carácter de impacto que genera nuevamente sobre oscilaciones y picos de carga en los componentes.
- **Paradas de emergencia:** En ciertas ocasiones es necesario realizar paradas de emergencia de la máquina, habitualmente por la detección de anomalías en el funcionamiento o para salvaguardar la integridad de la misma. Esto hace que la detención se tenga que realizar lo más rápidamente posible, siendo nuevamente un evento con cierto carácter violento que afecta a todo el tren de potencia.
- **Paradas:** Sin ser del orden de las paradas de emergencia, la fuerte inversión del sentido de par que implica una parada, también genera fuertes cargas.

Otra limitación impuesta al presente trabajo está relacionada con las condiciones en las que se dan estos eventos. Se podrían dar en cualquier rango de potencia de la máquina, pero esto implica que el número de simulaciones a realizar para el posterior entrenamiento de la red neuronal sea muy elevado y esto es contrario a una de las premisas fundamentales planteadas: el número de simulaciones detalladas tiene que ser reducido puesto que el coste de computación de muchas simulaciones se vuelve inabordable. Además el tener un gran número de posibles puntos de operación puede hacer pensar en un primer momento que puede complicar considerablemente que la red pueda converger. Esto es una apreciación personal que no se ha constatado, por lo que la utilización de alguna simulación bajo diferentes condiciones de operación se abre como una posible línea de trabajo para estudios posteriores.

Esta última limitación puede considerarse aceptable, ya que en última instancia el objetivo final de la red neuronal es la de ofrecer unas cargas dinámicas para los rodamientos y partiendo de la premisa que mencionamos en capítulos anteriores, las cargas que más afectan a su vida son aquellas que presentan valores más altos. También se podría añadir que las máquinas se diseñan para que trabajen el máximo de tiempo posible a carga nominal, por lo que considerando los eventos antes mencionados bajo carga nominal se considerarán los puntos de operación más dañinos y bajo las condiciones de operación que en teoría más se repetirán a lo largo de su vida.

Otra limitación impuesta está relacionada con uno de los eventos característicos, las pérdidas de red eléctrica. Se ha limitado el tiempo máximo entre la conexión y desconexión del generador a 6 segundos como máximo. Esto se debe a que al no disponer de un controlador real, con las técnicas de control rudimentarias utilizadas, la máquina pueda alcanzar estados que hacen no funcionar correctamente a la red y que tampoco son reales. Esta limitación impuesta tampoco es del todo desacertada ya que una estrategia de control empleada habitualmente es que cuando la pérdida de red supera un periodo de tiempo determinado la máquina se pare, por lo que casos con mayor tiempo de pérdida de red podrían estar cubiertos por las simulaciones de parada de emergencia en cierta manera.

Por último queda describir las limitaciones impuestas por la posterior utilización de la red neuronal para la obtención de nuevas cargas con inputs provenientes de simulaciones simplificadas. Dada la simplificación que se hace del tren de potencia en las simulaciones aeroelásticas, un sistema muelle amortiguador, las variables de las que se dispone son limitadas, pero suficientes. Toda la dinámica que se da en el interior de una multiplicadora de este tipo está relacionada con el comportamiento de sus componentes internos y por los inputs y outputs de esta, por lo que se consideran:

1. Par por la parte del rotor.
2. Velocidad por la parte del rotor.
3. Par por la parte del generador.
4. Velocidad por la parte del generador.

Estas variables además de ser suficientes para la representación del comportamiento interno están disponibles en las simulaciones aeroelásticas por lo que se ha considerado que son las variables adecuadas para nuestra red.

4.2 MODELO FÍSICO DINÁMICO

Para las simulaciones detalladas se ha utilizado un modelo denominado *modelo torsional*. En este tipo de modelo el principal grado de libertad considerado es el torsional, si bien el desplazamiento axial de los rodamientos, afectados por su rigidez axial también está permitido.

Esto hace que no todas las fuente de comportamiento no lineal descritas anteriormente se hayan considerado en el modelo. Están representados:

- Rigidez de engrane.
- Backslash o juego de engrane.
- Rigidez axial de rodamientos.

Este tipo de modelización ha sido seleccionada por los siguientes motivos:

- Disponibilidad:
 - De modelos: construir un modelo de este tipo es razonablemente asequible dentro del marco del proyecto. Además los modelos más complejos actualmente se realizan con unos pocos software comerciales que están al alcance de las posibilidades de las grandes empresas exclusivamente.
 - De datos: el número de datos necesarios no es muy elevado ni muy difícil de conseguir, se pueden tomar como ciertos valores procedentes de bibliografía sin comprometer la estabilidad del modelo.
- Tiempo de puesta a punto: Aparte del tiempo necesario para construir un modelo de estas características, el periodo de puesta a punto del mismo crece con el tamaño de este.

Con todo esto el tipo de modelo utilizado se considera óptimo para el presente estudio, ya que representa ciertas no linealidades del sistema, pero a su vez su complejidad es moderada y se presenta manejable.

4.2.1 TÉCNICAS DE MODELIZACIÓN Y SOFTWARE ELEGIDO

Actualmente en la industria de los aerogeneradores el estado del arte tiende a dos métodos de cálculo y simulación para este tipo de sistemas, el multibody flexible integrando sub-estructuras FEM y el FEM formulado en grandes desplazamientos. Es un campo de gran complejidad en el que se considera los 6 grados de libertad de todos los cuerpos unidos mediante relaciones no lineales, a la vez que se consideran las cargas aerodinámicas y todo gobernado por un sistema de control. Es tan complejo que actualmente solo dos software en el mercado pueden acometer la resolución de este problema con garantías bajo unos costes de licencia prohibitivos.

Como alternativa a estos software se nos presenta Matlab/Simulink [14], un entorno de desarrollo abierto donde el usuario puede desarrollar aplicaciones que se adapten a sus necesidades. Esta ha sido la opción utilizada tanto para la modelización y simulación como para el estudio de las redes neuronales.

El modelo detallado del tren de potencia ha sido desarrollado en Simulink. Simulink es un entorno

de diagramas de bloques para la simulación multidominio y el diseño basado en modelos. Se integra con Matlab, lo que permite incorporar algoritmos de Matlab en los modelos y exportar los resultados de la simulación a Matlab para llevar a cabo más análisis.

Las características de esta herramienta permiten que conociendo la mecánica que subyace debajo de cada componente estos puedan modelizarse de forma sencilla, modular y construir modelos realmente complejos. Pero el desarrollo de estos modelos, pese a ser sencillo, presenta su coste y alcanzar los estándares que manejan los software comerciales, pese a ser alcanzables, presenta costes muy elevados. El modelo torsional que se ha seleccionado encaja perfectamente dentro de las capacidades de Simulink.

La integración existente con Matlab hace que el pre y post proceso de los datos de las simulaciones se pueda hacer con facilidad, así como la integración junto con el módulo de redes neuronales que se utilizará más adelante.

4.2.2 DESCRIPCIÓN DEL MODELO

En el modelo utilizado se ha prescindido de la torre y la cimentación, por considerarse pequeña la afección que estos tienen en las simulaciones dadas las simplificaciones ya realizadas, con objeto de reducir los grados de libertad y así acelerar las simulaciones de detalle.

Por tanto el modelo utilizado consta de un rotor de tres palas, cada una de ellas modelizadas por elementos viga lineales, y un buje como una masa puntual. Un bastidor modelizado como un sólido rígido, un tren de potencia con la modelización torsional ya mencionada y un control rudimentario en el que la regulación se ha realizado por medio de funciones.

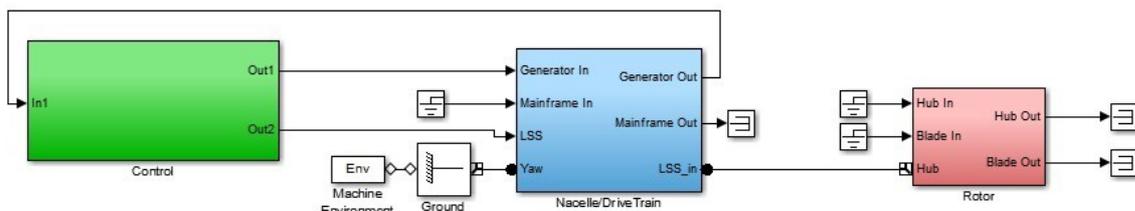


Ilustración 11: Diagrama completo del modelo en Simulink.

A continuación se describirán los componentes más relevantes del modelo para este estudio.

4.2.2.1 Tren de potencia

El tren de potencia consta de un eje principal, una multiplicadora con un acoplamiento flexible, un freno y un generador.

4.2.2.2 Eje principal

Físicamente el montaje de eje principal consta del eje propiamente dicho y de dos rodamientos. Al tratarse de una modelización torsional el eje se limita a un sólido rígido con su correspondiente masa e inercia y un rodamiento único que es quien soporta tanto las cargas radiales como axiales.

4.2.2.3 Multiplicadora

La multiplicadora, como ya hemos mencionado consta de dos brazos de reacción, una etapa planetaria, con su porta planeta, tres planetas, corona y solar, y dos etapas paralelas.

- **Brazos de reacción:** Son dos muelles lineales que unen el alojamiento de la multiplicadora, modelizado como un sólido rígido, y el bastidor de la máquina que también está modelizado como un sólido rígido.
- **Etapa Planetaria:** La corona, el porta planetas, los planetas y el solar están modelados por sólidos rígidos. Entre cada planeta y la corona tenemos un elemento de fuerza que representa la rigidez del engrane incluyendo el backlash ya mencionado. Entre cada planeta y el solar existe otro elemento de fuerza de engrane. El porta planetas está conectado rígidamente al eje principal de la máquina, soportado por un rodamiento, en lugar de dos, dada la modelización torsional tomada, que reacciona la carga axial y radial. Los planetas están unidos al porta planeta por un rodamiento que soporta la carga axial y radial.
- **Eje de baja:** Está formado por dos sólidos rígidos y un muelle torsional que representa su rigidez torsional. Se conecta al solar rígidamente, al bastidor por un único rodamiento debido a la modelización que ya hemos mencionado, y por una fuerza de engrane al eje intermedio. En el modelo el eje de baja y el solar se incluyen en el mismo bloque.
- **Eje intermedio:** Está formado por dos sólidos rígidos y un muelle torsional que representa su rigidez torsional. Se conecta al eje de baja por medio de una fuerza de engrane, al bastidor por un único rodamiento y por una fuerza de engrane al eje rápido.
- **Eje de salida:** Está formado por dos sólidos rígidos y un muelle torsional que representa su rigidez torsional. Se conecta al eje intermedio por una fuerza de engrane, al bastidor por un único rodamiento, y es elemento de salida de la multiplicadora que se conecta al freno del tren de potencia.

4.2.2.4 Controlador

Como ya se ha mencionado anteriormente el controlador es un componente crítico en la dinámica de un aerogenerador, tanto que es quien los regula, y más aún en eventos transitorios como los que tenemos entre manos. Al no disponer de un control de máquina real este se ha implementado de forma manual. Tampoco se disponía de un módulo aerodinámico para la simulación de cargas por lo que la solución adoptaba es la que habitualmente se utiliza, introducir un par directamente en el rotor. Así ciertos aspectos dinámicos secundarios del rotor pueden ser omitidos, pero se consideran aceptables por los estándares de la industria para cierto tipo de simulaciones.

Por ello para las simulaciones:

- La carga en el rotor se regula mediante una curva temporal que introduce par de forma similar a como lo haría un controlador.
 - **Arranque:** una recta que pasa de par cero a par nominal.
 - **Pérdidas de red:** durante la pérdida de red el par se reduce de carga nominal a cero por medio de una recta pronunciada y durante la recuperación de red la carga crece de cero a carga nominal por medio de otra recta pronunciada.
 - **Paradas:** La carga pasa de nominal a cero con dos diferentes pendientes según se trate de una parada de emergencia o una parada normal.



Ilustración 13: Gráfica del par de entrada normalizado en el rotor utilizado en la simulación: arranque en rampa, reacción del control a la pérdida de red y parada.

- El generador está gobernado por una curva que relaciona la velocidad de giro y el par resistente que este ofrece, saturándose con el valor de par máximo de generador una vez que se supera cierto número de rpm de giro. Para simular las pérdida de red lo que se hace es desconectar el par de reacción y volver a conectarlo pasado el tiempo que dura la pérdida. Durante las paradas de emergencia se sustituye la gráfica de par por un par constante que pretende asemejarse al par de frenado que impone el freno.

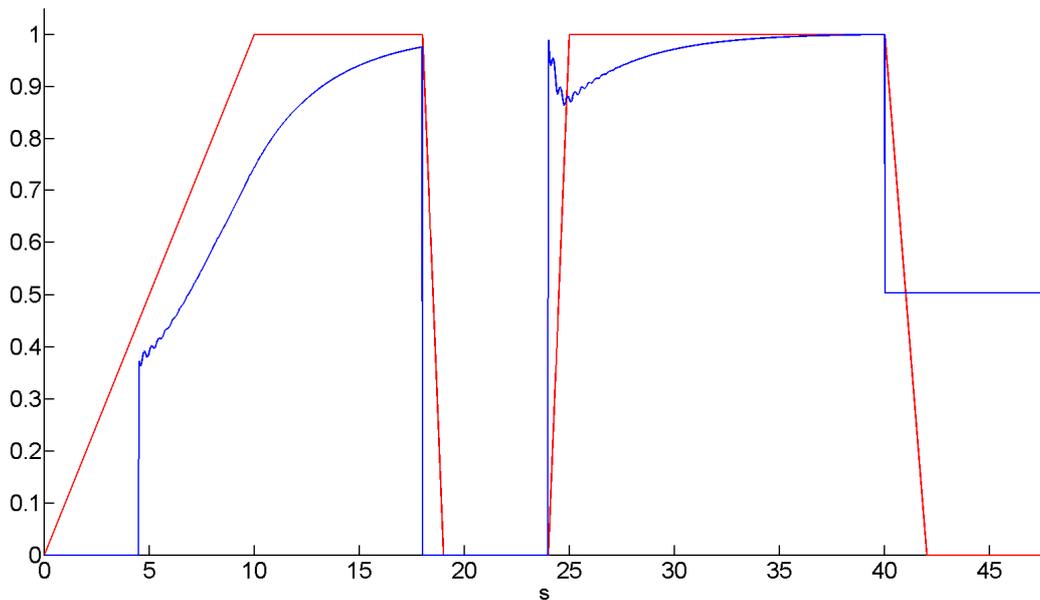


Ilustración 14: Representación del control realizado sobre el aerogenerador. Rojo: Curva de par de rotor. Azul: Curva de reacción de par del generador. Los pares se han normalizado para que estos tengan la misma escala en la gráfica.

Estas desconexiones del generador debidas a la pérdida de red o paradas, así como las nuevas conexiones, se han correspondido con el inicio y final de las curvas de par de rotor queriéndose asemejar a un comportamiento real. Este afán de simular un comportamiento real es debido a que si no se actuó como una máquina real, se dan estados de operación, como velocidades excesivas de giro de rotor o generador, que hacen que no haya un patrón de comportamiento del aerogenerador frente a eventos característicos, un patrón que impondría el control. La ausencia de este patrón hace que las condiciones de operación sean muy variadas y la red neuronal tenga a posteriori problemas para captar la dinámica y más problemas aun para representar la dinámica bajo un evento en el que no a sido entrenada.

4.2.3 SIMULACIONES

Una de las premisas principales de las simulaciones detalladas es la de no poder disponer de muchas de ellas. Esto se convertirá en un problema durante la fase de entrenamiento de la red neuronal ya que contra más datos dispongamos, mejor se entrenará esta. Este problema se abordará en el capítulo correspondiente al entrenamiento, el 4.3.

Para el entrenamiento de la red se han realizado simulaciones que incluyen los eventos característicos que se mencionaron en el apartado 4.1 que son: arranques, pérdidas de red eléctrica y paradas, normales y de emergencia.

Se han realizado tres simulaciones para el entrenamiento. Todas incluyen un arranque, dos de ellas incluyen pérdidas de red de diferente duración y otra un funcionamiento estacionario normal. Respecto a las paradas tenemos dos eventos de parada de emergencia y una parada normal. De estas simulaciones se extraerán los input de entrenamiento para nuestra red neuronal así como las cargas

que obtenemos en el rodamiento en estudio, como los valores objetivos de la red durante el entrenamiento.

En esta misma línea se ha realizado una simulación extra sobre la que se realizará la validación de la red, introduciendo los inputs y comparando los outputs que nos da la red con los obtenidos durante la simulación de validación.

Simulación 1: Entrenamiento

Se introduce una rampa de par de entrada y el generador está reaccionando desde el primer instante. Tras alcanzar la velocidad que corresponde al par nominal de generador, se pierde la red durante 2 segundos y tras recuperar el funcionamiento estacionario, se hace una parada de emergencia.

Las señales que se utilizarán como input de la red en el entrenamiento se muestran en la siguiente figura:

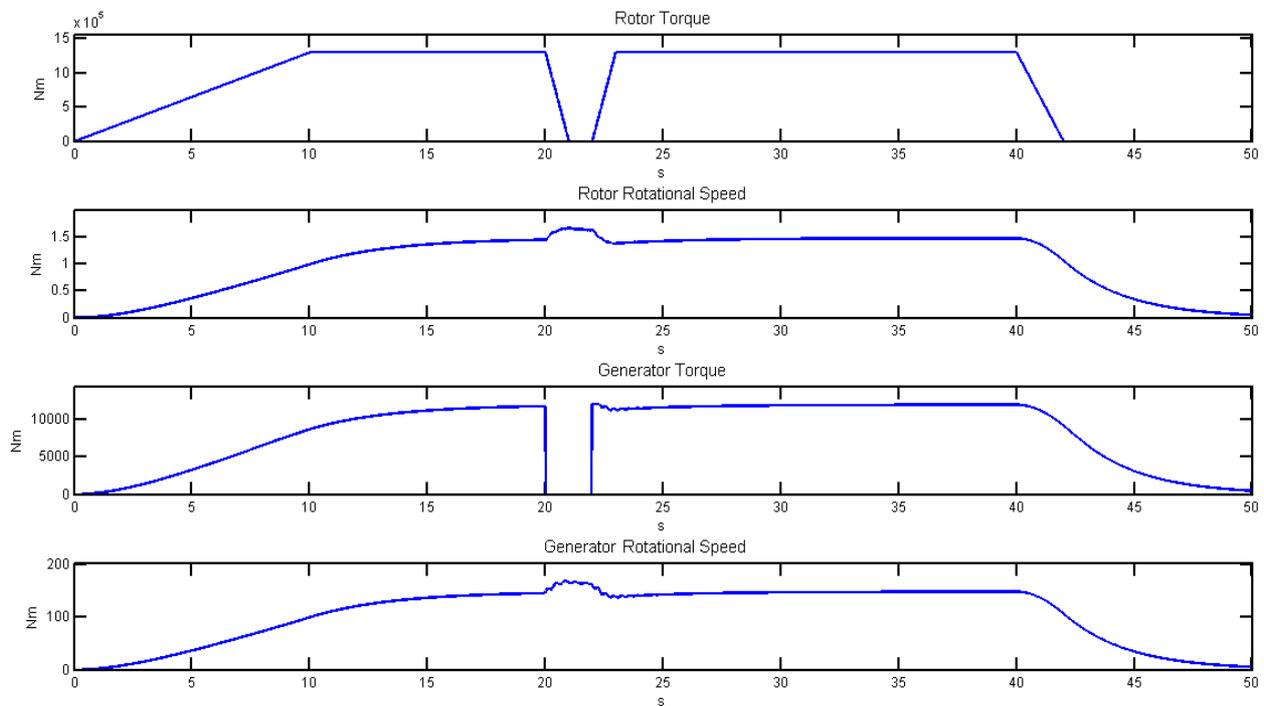


Ilustración 15: Señales que se tomaran como input para el entrenamiento proveniente de la simulación 1.

La señal de carga que se usará como objetivo para la red durante el entrenamiento es:

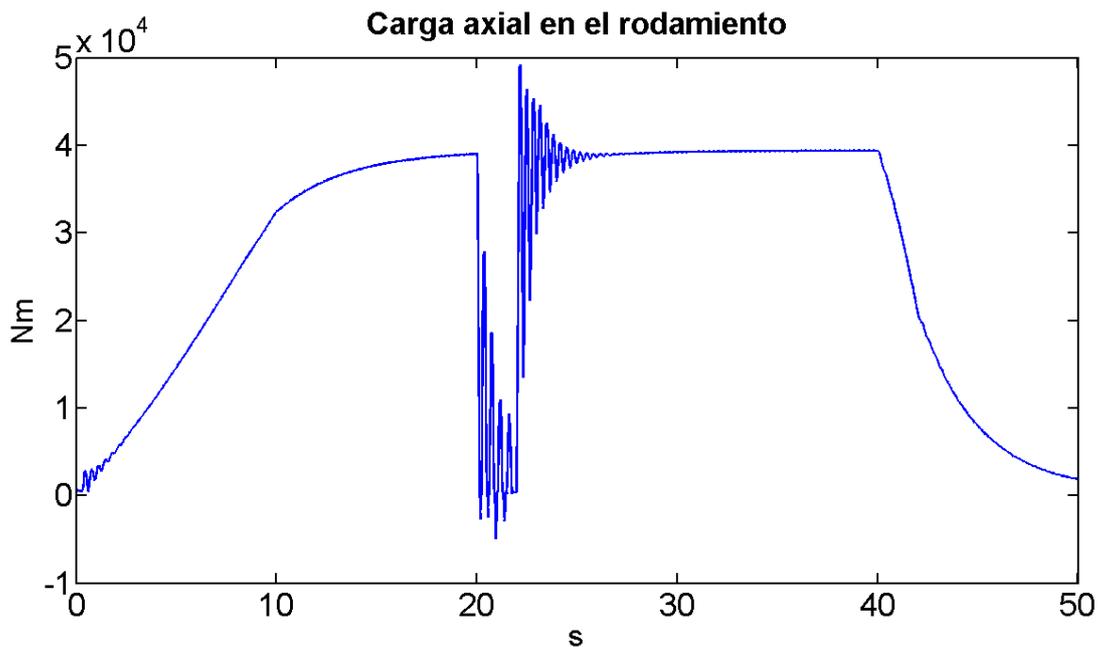


Ilustración 16: Curva objetivo para el entrenamiento proveniente de la simulación 1.

Simulación 2: Entrenamiento

Se introduce una rampa de par de entrada. En cierto instante, cuando se superan las rpm de conexión, entra el par del generador. Tras alcanzar la velocidad, esta se mantiene durante un periodo de tiempo. Luego se hace una parada normal.

Las señales que se utilizarán como input para la red durante el entrenamiento se muestran en la siguiente figura:

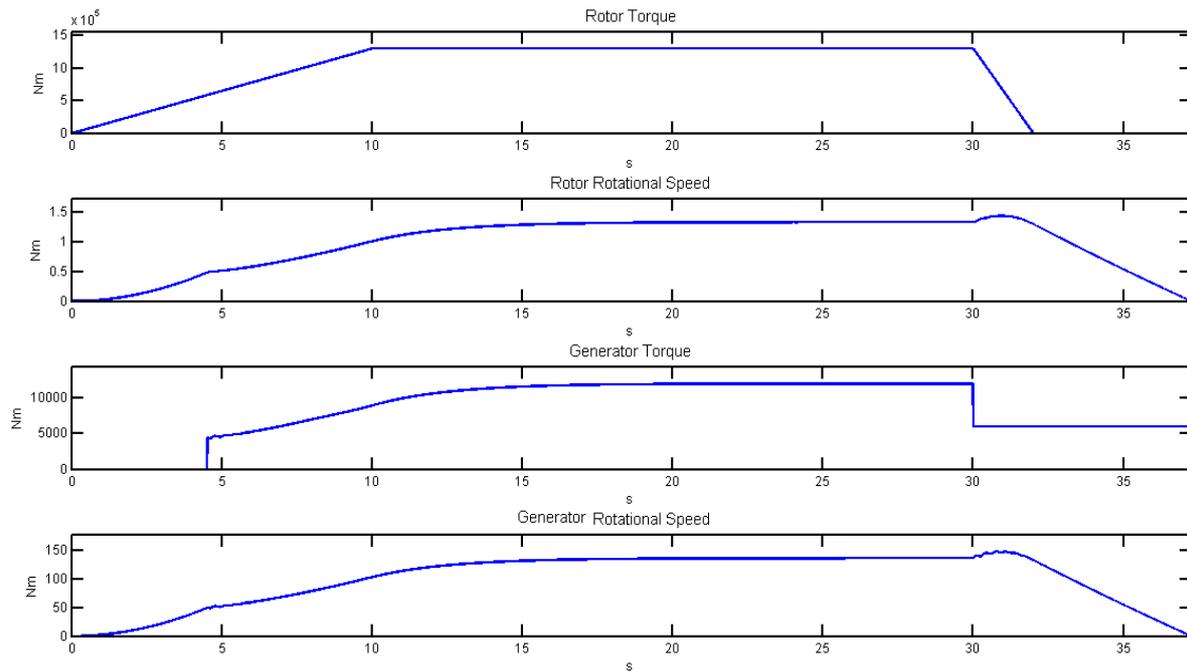


Ilustración 17: Señales que se tomaran como input para el entrenamiento proveniente de la simulación 2.

La señal de carga que se usará como objetivo para la red durante el entrenamiento es:

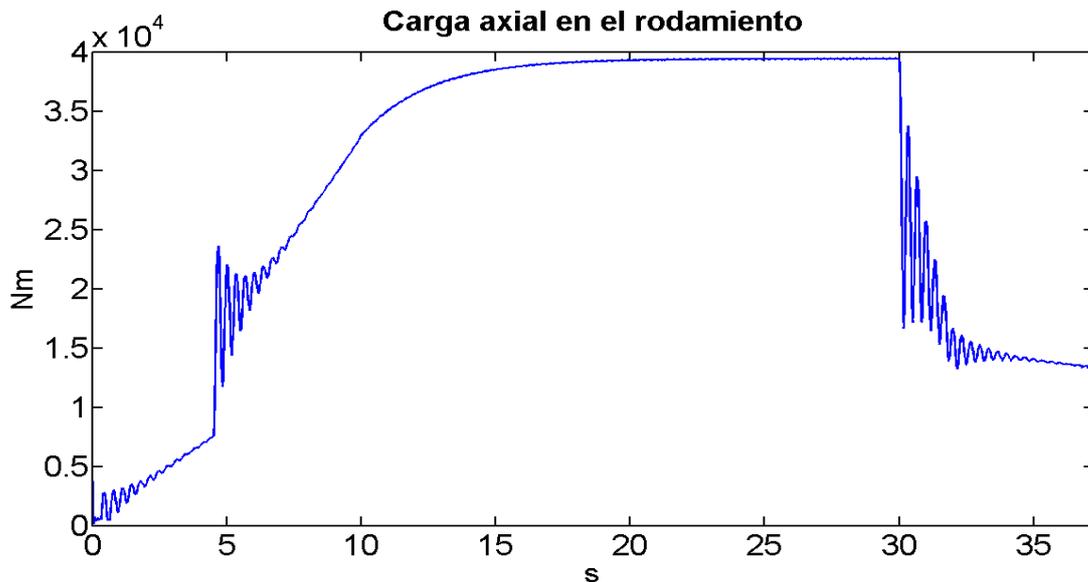


Ilustración 18: Curva objetivo para el entrenamiento proveniente de la simulación 2.

Simulación: 3 Entrenamiento

Se introduce una rampa de par de entrada y en cierto instante, cuando se superan ciertas rpm, entra el par del generador. Tras alcanzar la velocidad que corresponde al par nominal de generador, se pierde la red durante 6 segundos y tras recuperar el funcionamiento estacionario se hace una parada de emergencia.

Las señales que se utilizarán como input para el entrenamiento se muestran en la siguiente figura:

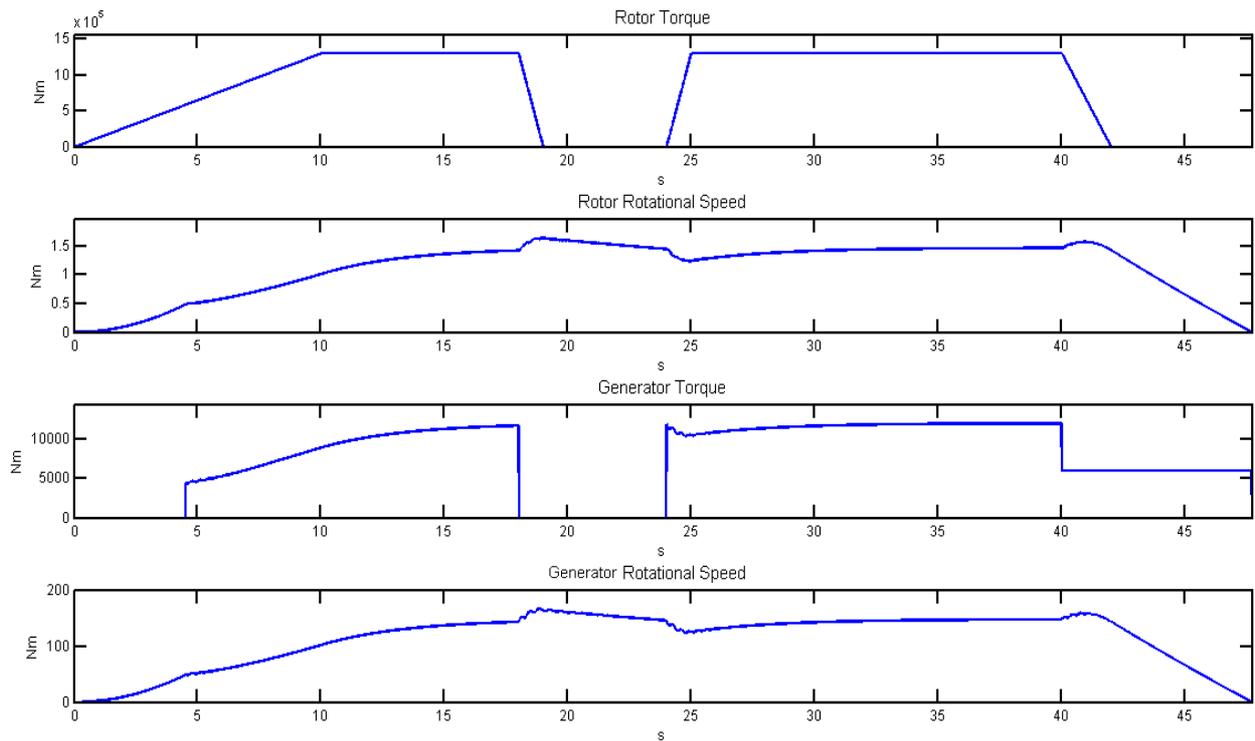


Ilustración 19: Señales que se tomaran como input para el entrenamiento proveniente de la simulación 3.

La señal de carga que se usará como objetivo para la red durante el entrenamiento es:

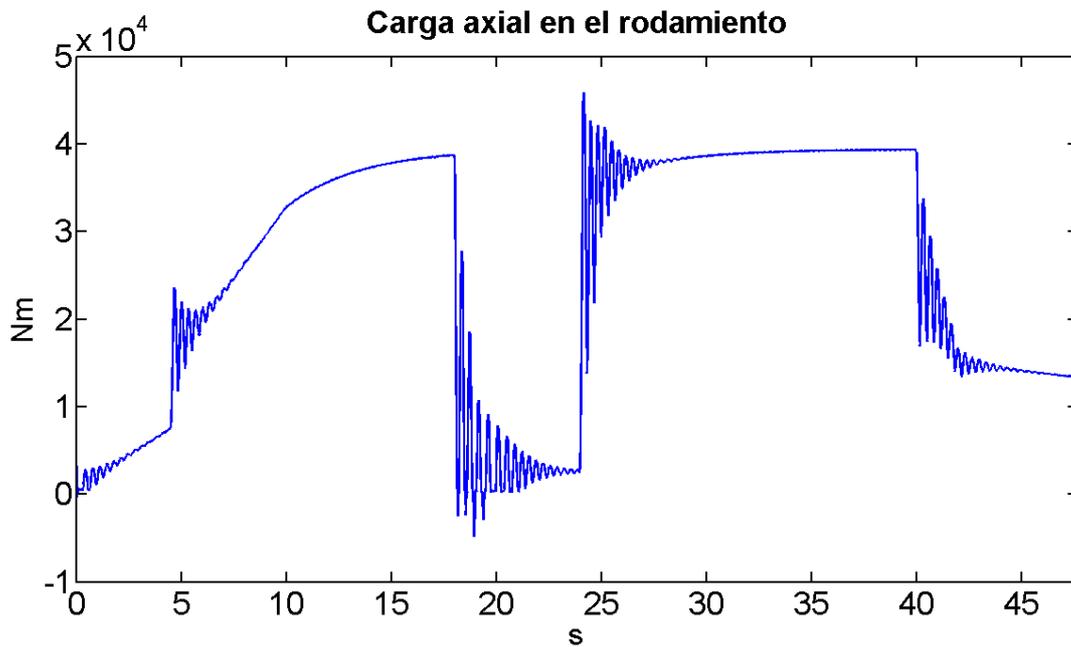


Ilustración 20: Curva objetivo para el entrenamiento proveniente de la simulación 3.

Las señales que se utilizarán como input para la validación se muestran en la siguiente figura:

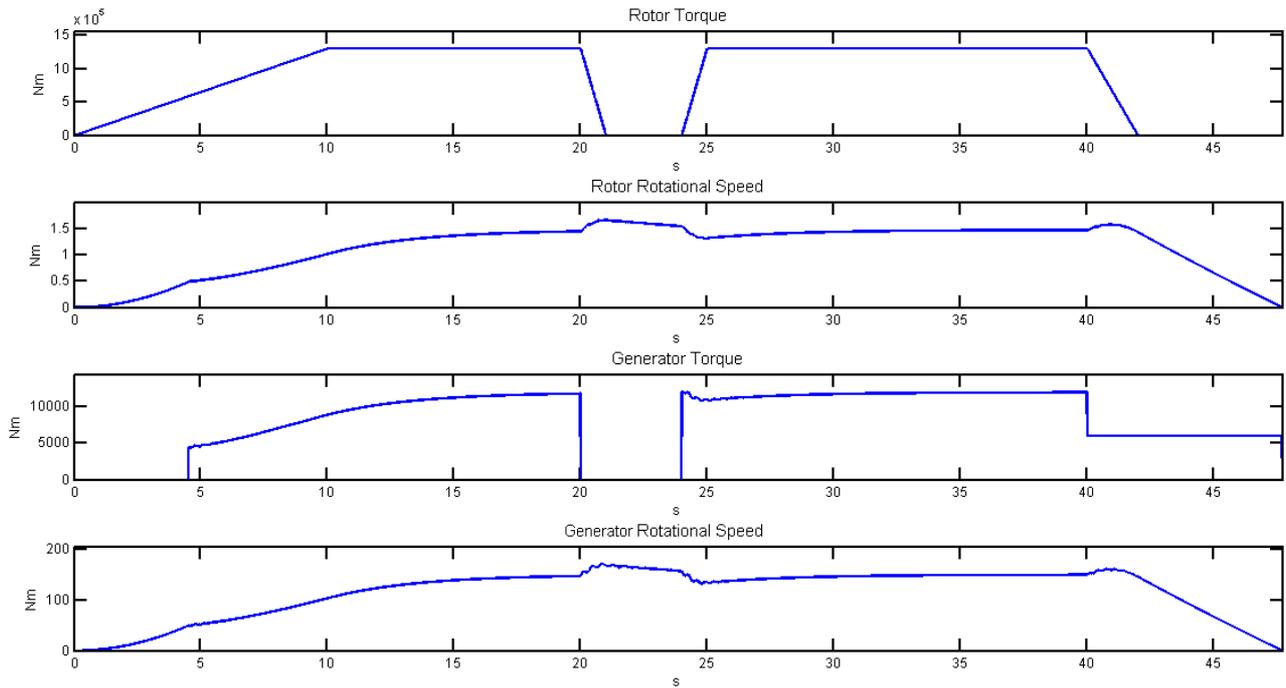


Ilustración 21: Señales que se tomaran como input para la validación.

La señal de carga que se usará durante la validación es:

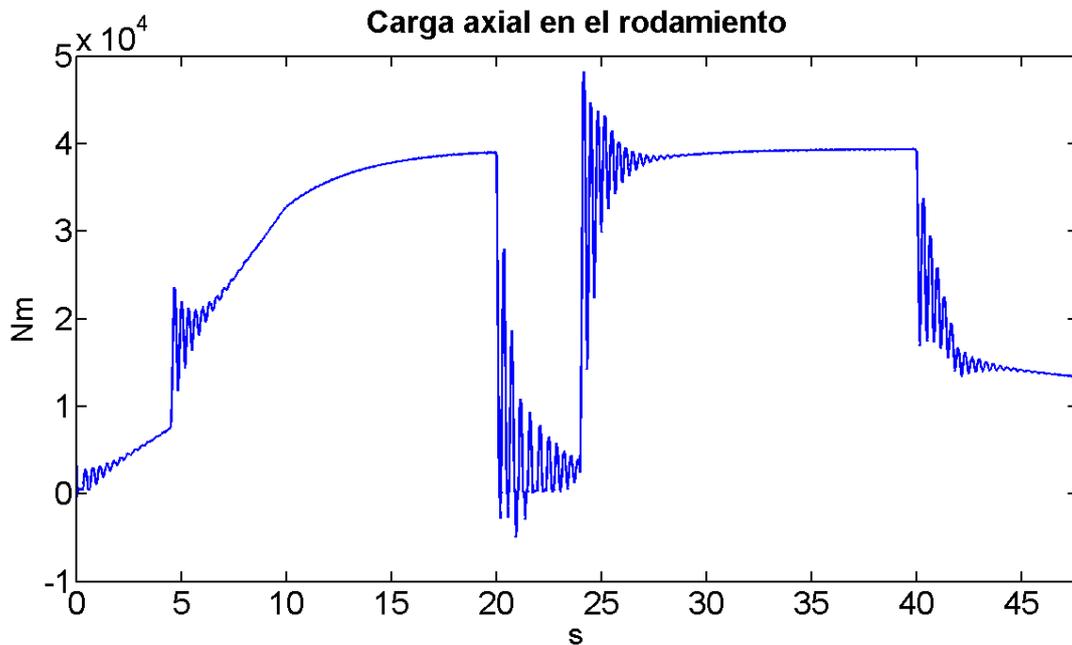


Ilustración 22: Curva objetivo para la validación.

4.3 MODELO NEURONAL

Una vez descrito nuestro modelo, determinados los casos de carga, seleccionadas las variables que serán input/output para nuestro modelo y realizadas las simulaciones, es el momento de comenzar con el trabajo realizado con las redes neuronales. Para ello se ha utilizado el software Matlab y su *Neural Network Toolbox*. Este paquete consta de interfaces gráficas que inicialmente ayudan a familiarizarse con las redes neuronales así como con los algoritmos de entrenamiento y procesamiento de la información. Sin embargo para aprovechar todo su potencial la utilización directa de scripts y funciones es la vía más efectiva. Además de para el propio entrenamiento de la red, Matlab ha sido de gran ayuda a la hora de pre procesar información y post procesar los resultados.

4.3.1 TIPOLOGÍA DE RED

El objeto de nuestra red neuronal es la de modelar un sistema dinámico no lineal. Existen diferentes tipologías de red neuronal y más concretamente para el modelado dinámico las tipologías más habituales son las siguientes. La diferencia fundamental es que unas son de carácter estático y otras de carácter dinámico.

- **NARX (Nonlinear Autoregressive Network with Exogenous input):** Se trata de una red dinámica recurrente que está basada en el modelo lineal ARX de difundido uso en series temporales [14]. La principal ventaja de la red NARX sobre una red feed-forward es que permite ganar grados de libertad al incluir la predicción de un período como dato en períodos siguientes, resumiendo información de las variables exógenas, permitiendo incluir menos rezagos de las mismas y resumiendo el número de parámetros “a estimar”.

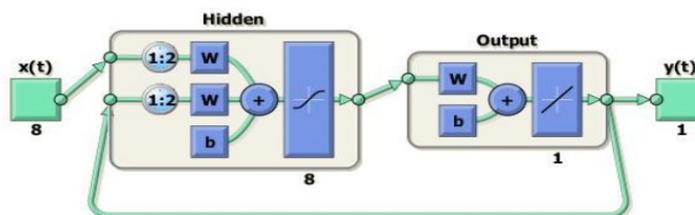


Ilustración 23: Red neuronal tipo NARX

- **FEED-FORWARD:** Se trata de la tipología más común de las redes neuronales. Son de carácter estático y la principal diferencia respecto a las anteriores es que no constan de información sobre predicciones previas. Constan de una capa de entrada, las capas ocultas y una capa de salida.

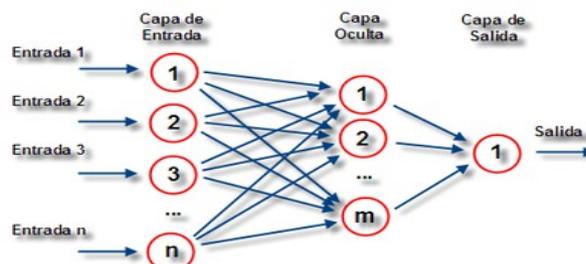


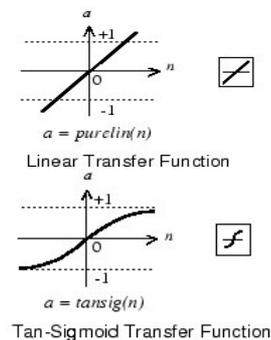
Ilustración 24: Red neuronal tipo Feed-Forward

Inicialmente se realizaron pruebas con las diferentes tipologías mencionadas, pero ya desde los primeros intentos las redes feed-forward comenzaron a presentar los resultados más prometedores. Además dada la mayor simplicidad de estas, fueron seleccionadas para el desarrollo del presente trabajo. Si bien la tipología NARX no se descartó por completo ya que la idea inicial de considerar los valores proporcionados por la red en instantes de tiempo previos resultaba atractiva para la resolución del problema planteado.

4.3.2 FUNCIONES DE TRANSFERENCIA

Como ya se mencionó en el apartado introductorio dedicado a las redes neuronales, existen multitud de funciones de transferencia. En nuestro caso se han utilizado dos.

- Función de transferencia lineal
- Función de transferencia tangente hiperbólico



Mediante estas dos funciones se ha pretendido captar los dos comportamientos de nuestro modelo, uno lineal cuando no hay cambios bruscos en los inputs y otro no lineal cuando los hay. Destacar que la selección de la función de transferencia en la capa adecuada ha sido de vital importancia para la obtención de resultados, y que un cambio de alguna de ellas desvirtuaba por completo los mismos.

En las primeras fases de la selección de las funciones de transferencia se utilizaron únicamente funciones lineales para ver la respuesta obtenida. Rápidamente se alcanzaban los parámetros de parada impuestos para el entrenamiento, pero la validación no era satisfactoria. La red proporcionaba buenos resultados para los valores medios de la nueva serie temporal, pero no así los picos característicos de esta. Como ya hemos mencionado estos picos característicos se deben a la no linealidad del sistema bajo ciertas condiciones de inputs, por lo que se fueron sustituyendo progresivamente las neuronas lineales por neuronas con función de transferencia tangente hiperbólica. Estos cambios hicieron que la dinámica del sistema comenzase a ser representada en los resultados.

4.3.3 ARQUITECTURAS NEURONALES

La selección de la arquitectura adecuada ha sido uno de los puntos fuertes para la obtención de los resultados. Partiendo de la tipología de red neuronal Free-Forward, se han realizado pruebas comenzando por la red más sencilla con una capa de entrada, una capa oculta y una de salida, obteniéndose los mejores resultados con dos capas ocultas.

En la capa de entrada al ser cuatro las variables seleccionadas como input, en primera instancia parecía razonable considerar cuatro neuronas en esta capa inicial haciendo que las siguientes capas

definieran los planos separadores y una capa de salida con una única neurona, ya que la salida del sistema está compuesta de una única variable. Se fueron aumentando el número de neuronas de la capa intermedia, pero a pesar de obtenerse mejores resultados, la dinámica no lineal del sistema seguía sin aparecer.

Por ello se introdujo una nueva capa intermedia en la arquitectura de forma que la primera capa oculta fuese quien definiera los planos separadores que delimitan la región buscada y la segunda capa de neuronas definiera la región convexa que nos interesa. En la primera capa oculta se utilizó distinto número, siempre grande, de neuronas ya que debido al comportamiento del sistema el número de planos separadores era alto, mientras que en la segunda, el número de neuronas era reducido. Estos cambios, junto con la modificación del tipo de neurona utilizado en cada capa que se mencionó en el apartado anterior, hicieron que los resultados comenzasen a mostrar comportamientos similares a los deseados. El último cambio respecto a la arquitectura que produjo los resultados que posteriormente se mostrarán fue el aumentar el número de neuronas en la capa de entrada. La arquitectura y las funciones de transferencia por la que finalmente se optó fue:

- Capa de entrada: 8 neuronas con función de transferencia tangente hiperbólico.
- Primera capa oculta: 60 neuronas con función de transferencia tangente hiperbólico.
- Segunda capa oculta: 3 neuronas con función de transferencia tangente hiperbólico.
- Capa de salida: 1 neurona con función de transferencia lineal.

4.3.4 ENTRENAMIENTO

Durante el proceso de selección de las funciones de transferencias y de la arquitectura se mostraba evidente la gran influencia que el entrenamiento ejercía sobre los resultados obtenidos, sobre todo los datos que se utilizan para ello, más que los propios debidos al algoritmo de back-propagation utilizado durante el entrenamiento. Al tratarse de un algoritmo back-propagation el entrenamiento es de tipo supervisado.

4.3.4.1 ALGORITMO DE ENTRENAMIENTO

El algoritmo back-propagation utilizado durante el entrenamiento ha sido el algoritmo de Levenberg-Marquardt [14].

Este método, como los métodos de cuasi-Newton fue diseñado para una aproximación de segundo orden sin tener que computar la matriz Hessiana. Cuando la función de rendimiento tiene la forma de una suma de cuadrados, típica durante el entrenamiento de redes tipo feed-forward, la matriz Hessiana se puede aproximar como:

$$H=J^T J \tag{4.1}$$

y el gradiente se puede computar como

$$g=J^T e \tag{4.2}$$

donde J es el Jacobiano que contiene las primeras derivadas de los errores de los bias. La matriz Jacobiana puede ser computada a través de las técnicas convencionales de back propagation que es mucho menos complejo que computar la matriz Hessiana.

Para la computación tipo Neuwtoniana que utiliza este algoritmo la matriz Hessiana se aproxima tomando el algoritmo la siguiente forma:

$$x_{k+1} = x_k - [J^T J + \mu I]^{-1} J^T e \quad (4.3)$$

Cuando el escalar μ vale cero, es exactamente el método de Newton usando la aproximación de la matriz Hessiana. Cuando μ es mayor, este se convierte en el del gradiente descendiente de paso pequeño. El método de Newton es más rápido y más preciso, por ello μ se reduce después de cada paso satisfactorio y únicamente se aumenta tras un aumento de la función de rendimiento.

El entrenamiento se da por concluido cuando:

1. El número de iteraciones máximo ha sido alcanzado.
2. El máximo tiempo de entrenamiento se ha excedido.
3. El rendimiento reduce al mínimo el objetivo, el error.
4. El rendimiento del gradiente cae por debajo de un parámetro.
5. μ excede el valor establecido como máximo.

4.3.4.2 PROCESO DE ENTRENAMIENTO

Durante el proceso de entrenamiento, como ya se ha mencionado, se han probado diferentes arquitecturas de red, así como la utilización de las diferentes funciones de transferencia en cada capa, pero algo que se fue detectando conforme se avanzaba con el desarrollo del proyecto fue la gran influencia que tenían los input como los outputs utilizados. Uno de los factores a los que se le puede achacar esta fuerte dependencia es la poca cantidad de datos utilizados para el entrenamiento, ya que a priori para el entrenamiento de redes neuronales una de las premisas principales es la disponer de un número de datos elevado. Como ya se ha comentado esto está contrapuesto con los objetivos del proyecto, ya que la utilización de redes neuronales en el ámbito propuesto implica que el número de datos disponible sea bajo. Cuatro han sido principalmente los factores sobre los que se ha trabajado para mitigar este problema: el controlador de la máquina, el ruido en los datos objetivo durante el entrenamiento, la ponderación de datos con la dinámica lineal y dinámica no lineal y el sobreentrenamiento. Se detallan a continuación.

Controlador del aerogenerador

Se ha constatado la gran influencia que tiene el controlador sobre la máquina. La utilización de un patrón de control a lo largo de los diferentes eventos simulados a sido fundamental para obtener simulaciones realistas, es decir que no se diesen condiciones como que por ejemplo durante una pérdida de red la velocidad de giro del aerogenerador alcanzara dos veces su velocidad nominal. Ha

sido muy importante para que cuando estos eventos cambian algo entre sí, el tiempo de parada por ejemplo, todo mantenga una coherencia. De no ser así la casuística de condiciones de trabajo se volvería inabordable, lo que ha hecho que el trabajo sobre las simulaciones haya tenido que ser intenso.

Ruido en los datos objetivo durante el entrenamiento

Las simulaciones realizadas, dadas las particularidades de la modelización, requieren de un paso de integración fijo y muy pequeño para que la estabilidad del modelo no se vea comprometida. La utilización de un paso de integración muy pequeño implica que aparezcan altas frecuencias en la señal que desvirtúan la señal original por el ruido que estas introducen. En nuestro caso lo que nos interesa es la componente fundamental de la señal, las oscilaciones principales de mayor amplitud, por lo que se ha realizado un filtrado previo a la señal que se utiliza como objetivo para el entrenamiento. La parte de la señal que se ha considerado ruido hacía que las red no captase la dinámica fundamental del sistema haciendo que los resultados no fuesen representativos.

Ponderación de datos con dinámica lineal y dinámica no lineal

La utilización de un paso de integración fijo hace que las simulaciones tengan todos sus puntos equiespaciados. Esto implica que en la parte donde el sistema tiene una dinámica más lineal tenga el mismo número de puntos que la parte no lineal. Durante las simulaciones realizadas las partes no lineales son eventos aislados, siendo el número de puntos de la serie correspondientes a estos, más reducidos frente a la parte lineal. Esto hace que durante el entrenamiento de la red la parte lineal tome más peso, haciendo que esta “aprenda” correctamente en detrimento de “aprender” el comportamiento no lineal del sistema. Para remediar esto se han eliminado puntos de la parte lineal que no aportan información adicional, ponderando la parte lineal y no lineal a lo largo de la simulación.

Sobreentrenamiento

Al disponer de pocos datos realizar un único entrenamiento sobre ellos no es suficiente para que la red responda correctamente, por lo tanto es necesario realizar varios entrenamientos sobre los mismos. Ha sido crítico el número de entrenamientos realizados sobre los mismos datos ya que un entrenamiento reducido hace que la red no capte la dinámica y un exceso de este hace que comiencen a aparecer resultados anómalos. La solución aquí ha sido de compromiso.

Una vez definidos los casos de carga, realizadas las simulaciones, definida la red neuronal y el patrón de entrenamiento a seguir, es el momento de centrarse en el análisis de los resultados obtenidos bajo todas estas premisas.

5 RESULTADOS

Los resultados que se muestran a continuación corresponden a los resultados que la red ofrece sobre los resultados de entrenamiento, con objeto de mostrar como la red es capaz de captar la dinámica del sistema y la validación de la red bajo las nuevas condiciones que se describieron en el capítulo anterior.

Para ello el entrenamiento se ha realizado bajo las siguientes condiciones:

Parámetro	Descripción	Valor
Maximum Epochs	Número de iteraciones durante entrenamiento.	25000
Maximum Training Time	Máximo tiempo permitido para el entrenamiento.	No se ha impuesto limitación por el tiempo de entrenamiento.
Performance Goal	Objetivo para el error.	0
Minimum Gradient	Mínimo valor permitido para el gradiente del algoritmo de entrenamiento.	1e-15
Maximum Validation Checks	Numero de validaciones para el cual el resultado de la red se considera aceptado una vez que uno de los criterios de parada ha sido alcanzado.	200
Mu	Valor de mu según se describió en el apartado 4.3.4.1 correspondiente al algoritmo de entrenamiento.	0.1
Mu Decrease Ratio	Ratio para el decrecimiento de mu cuando una iteración resulta satisfactoria.	0.001
Mu Increase Ratio	Ratio para el aumento de mu cuando una iteración resulta no ser satisfactoria.	10
Maximum mu	Valor máximo permitido para mu durante el entrenamiento.	10000000

Tabla 4: Parámetros y valores utilizados durante el entrenamiento.

Las siguientes gráficas muestran como la red responde a los eventos para los que ha sido entrenada, un vez este se ha dado por concluido. Se pretende mostrar como la red capta los rasgos dinámicos más característicos de la serie temporal para cada una de las simulaciones utilizadas para el entrenamiento. El azul corresponde a los valores de carga axiales obtenidos durante la simulación en el rodamiento de la etapa de alta de la multiplicadora. El color rojo muestra los resultados de

carga que ofrece la red cuando los input de la simulación son introducidos en la red.

El entrenamiento se ha realizado introduciendo las tres series temporales en un mismo vector consecutivamente, de ahí los tiempos que se observan en el eje de abscisas en las siguientes figuras.

Para la simulación 1:

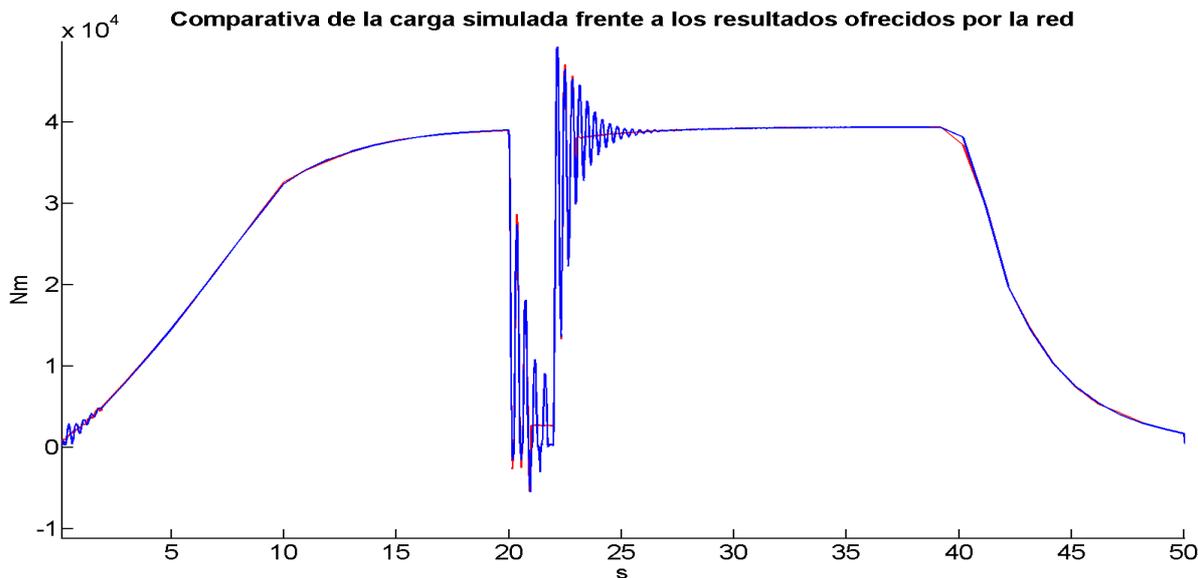


Ilustración 25: Comparativa de cargas de salida para la simulación n^o1.

Para la simulación 2:

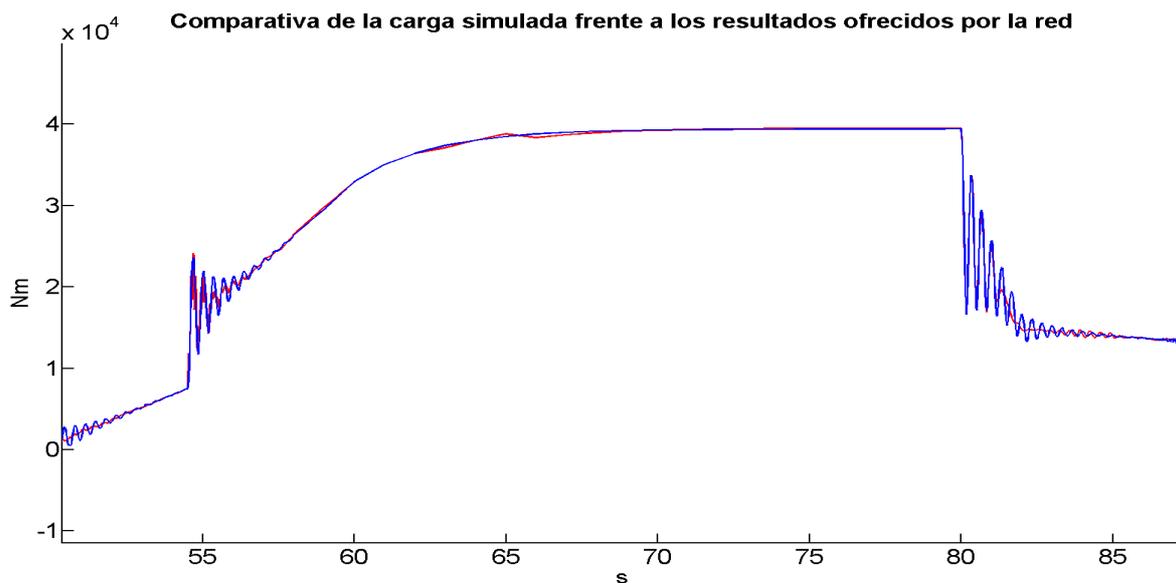


Ilustración 26: Comparativa de cargas de salida para la simulación n^o2.

Para la simulación 3:

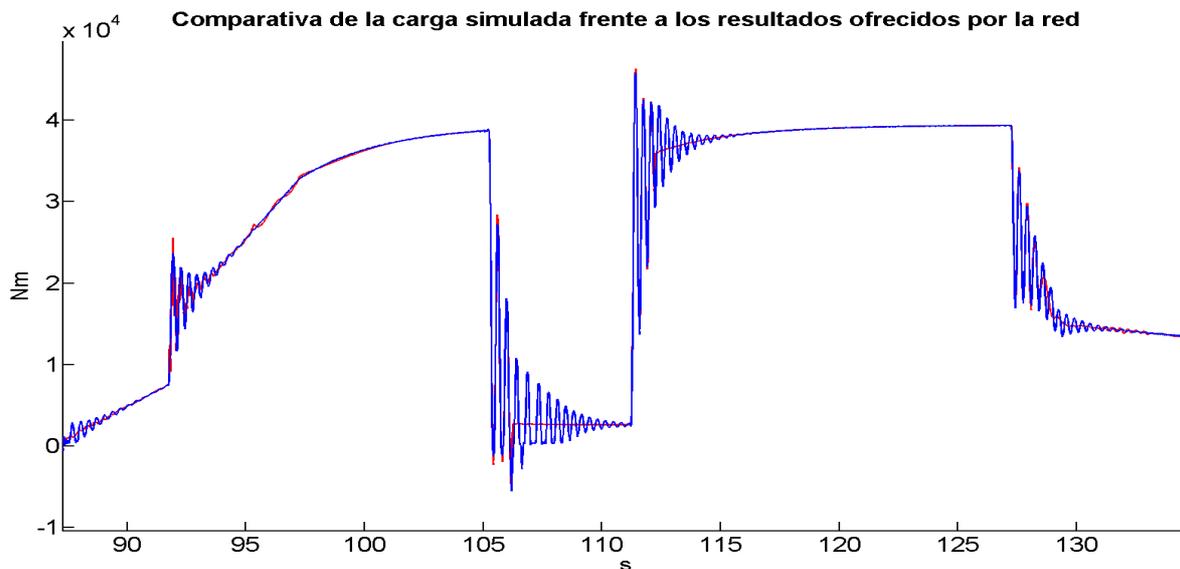


Ilustración 27: Comparativa de cargas de salida para la simulación n°3.

Como se puede apreciar en las figuras 25, 26 y 27 la dinámica correspondiente a los eventos no lineales característicos a estudiar, como son el arranque, las pérdidas de red y las paradas, son captadas satisfactoriamente por la red. A continuación se muestran en detalle:

Conexión del generador:

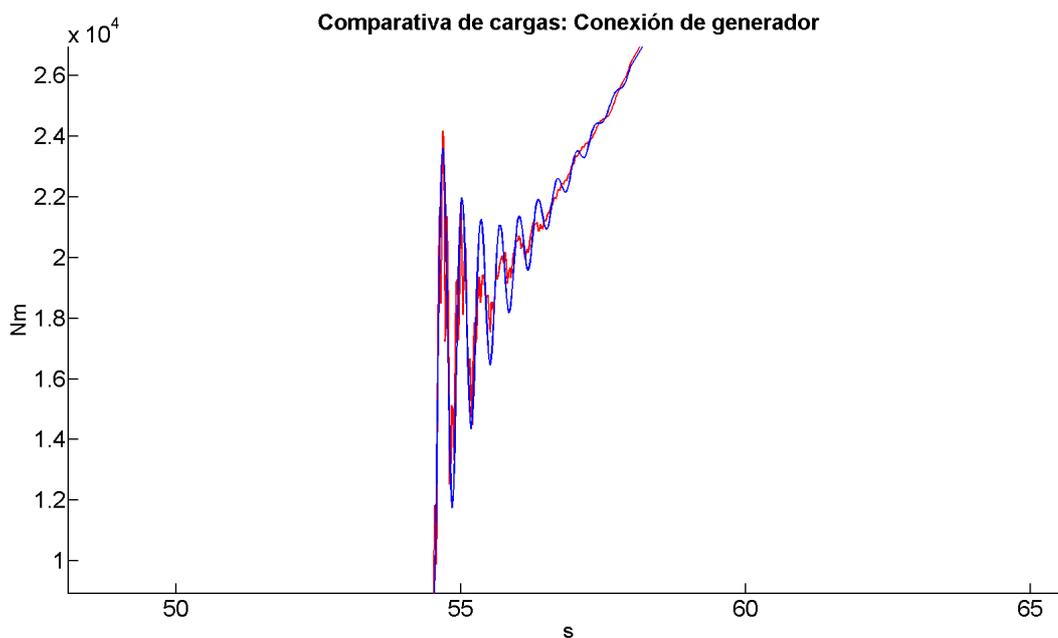


Ilustración 28: Detalle de la conexión de generador.

Pérdida de Red:

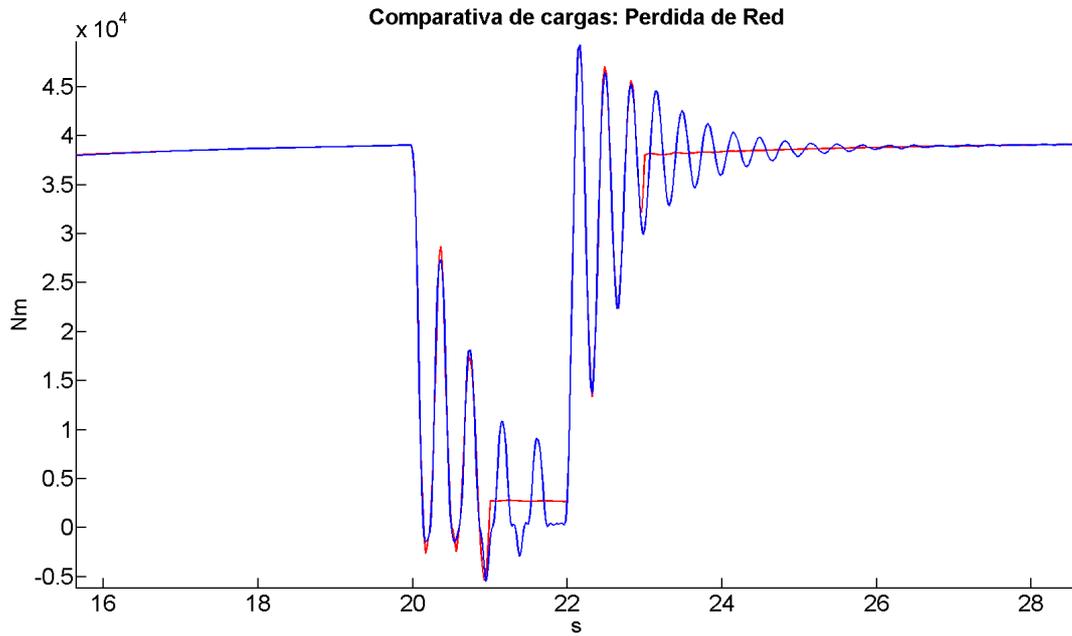


Ilustración 29: Detalle de pérdida de red.

Parada de emergencia:

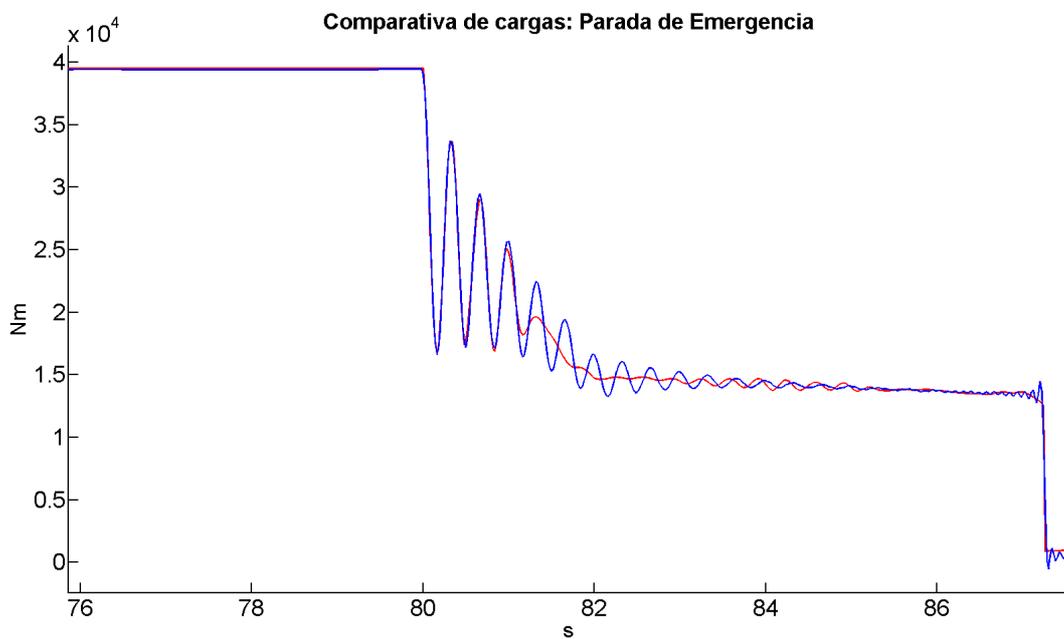


Ilustración 30: Detalle de una parada de emergencia.

De un primer vistazo sobre las comparativas se observa como la red es capaz de seguir las simulaciones a grandes rasgos.

Se puede apreciar como la red capta la dinámica no lineal del sistema para las primeras sobre oscilaciones en todos los eventos característicos. Una vez los primeros picos han sucedido, la red nos da un valor medio de la respuesta real. El seguimiento no es perfecto pero se considera satisfactorio ya que los mayores picos son captados y cuando el seguimiento no es del todo preciso la red nos ofrece un valor medio.

Una vez mostradas las capacidades de la red para captar la dinámica del sistema, se muestran los resultados correspondientes a la validación, donde la red responde a un evento para el que no ha sido entrenado, y para el que debiera representar la dinámica del sistema. El azul corresponde a los valores de carga axial obtenidos durante la simulación en el rodamiento de la etapa de alta de la multiplicadora. El color rojo muestra los resultados de carga que ofrece la red cuando los input de la simulación son introducidos en la red.

Validación 1:

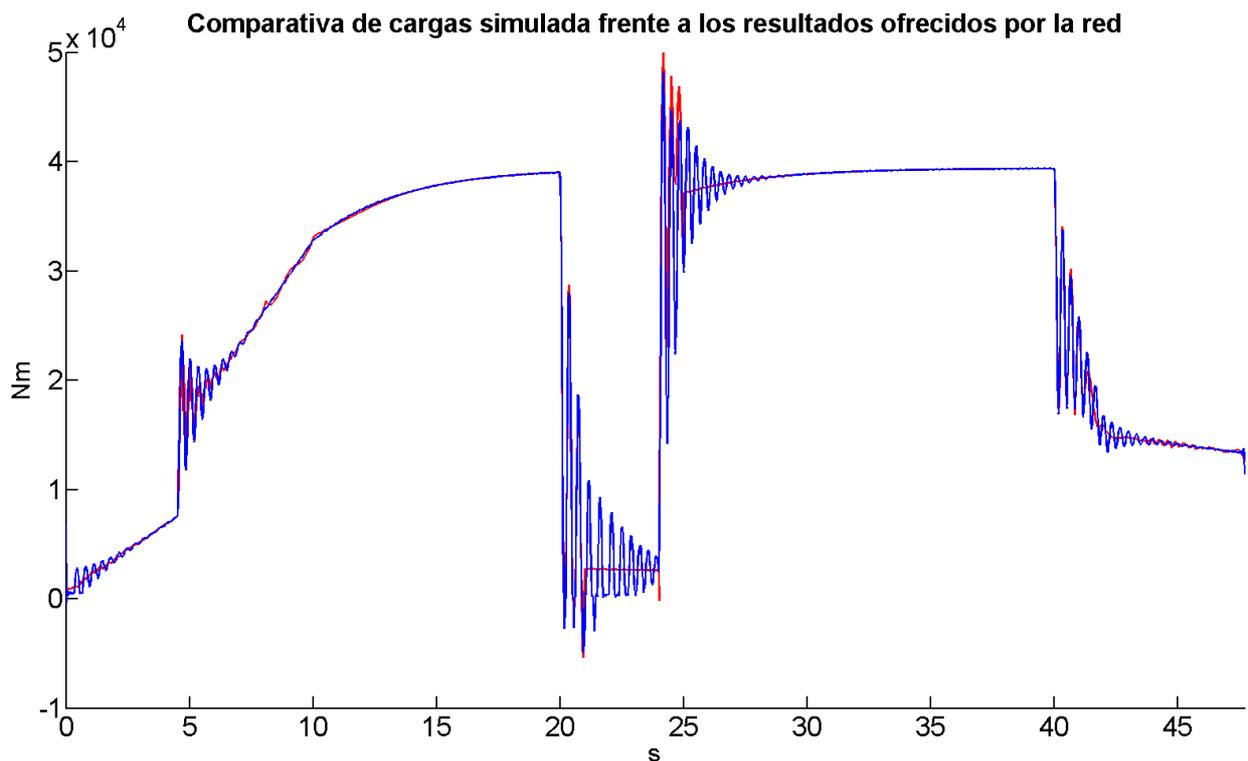


Ilustración 31: Comparativa de cargas de salida para la validación de la red.

A continuación se muestran más en detalle los eventos característicos.

Conexión del generador:

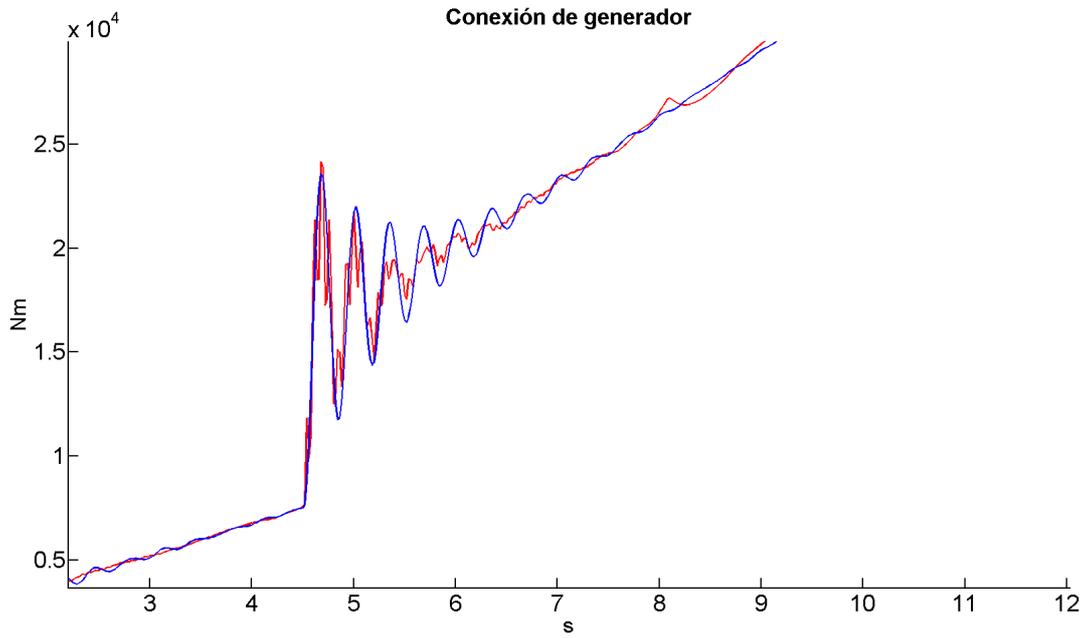


Ilustración 32: Detalle de la conexión de generador en la validación.

Pérdida de Red:

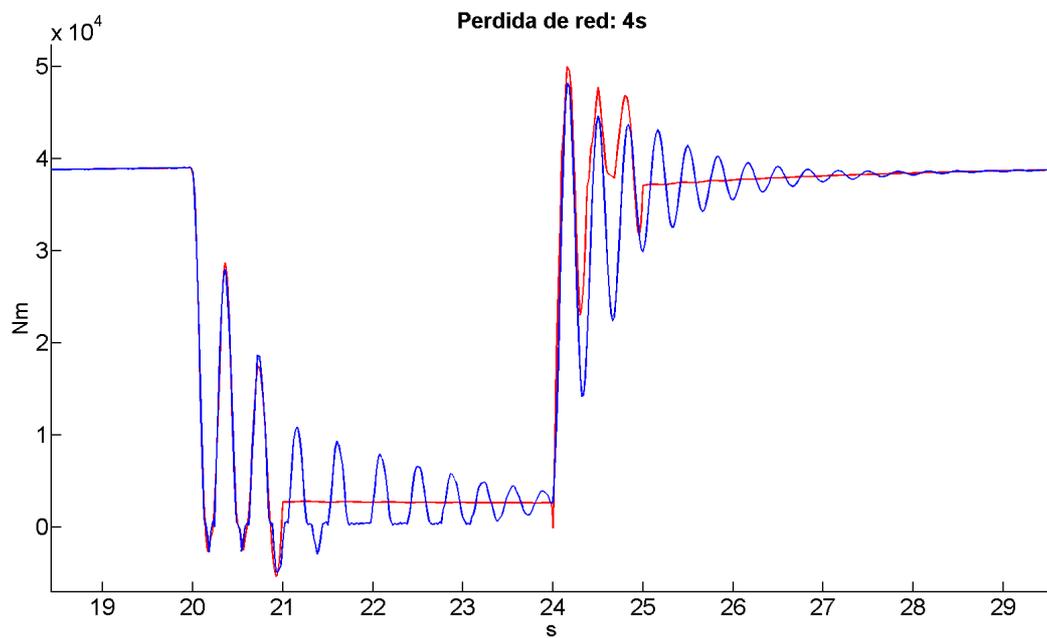


Ilustración 33: Detalle de la pérdida de red en la validación.

Parada de emergencia:

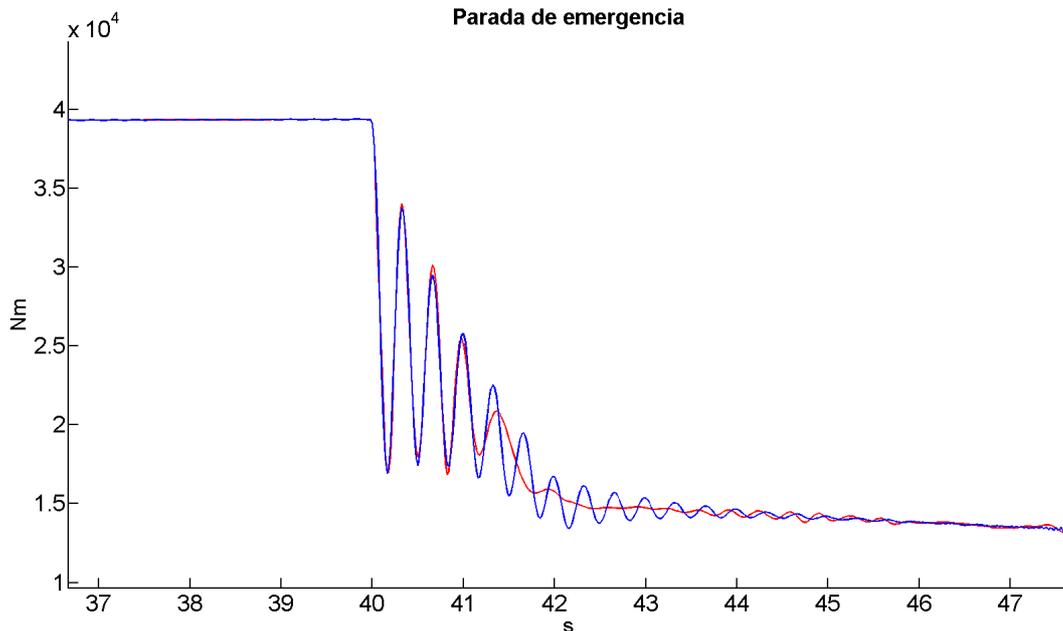


Ilustración 34: Detalle de la parada de emergencia en la validación.

En los resultados mostrados se puede apreciar como la red nos ofrece unos resultados muy similares a los obtenidos por la simulación para la cual no fue entrenada. Todos los eventos característicos son representados por la red. A continuación se comentan en detalle:

La conexión del generador es representada perfectamente por la red. Esto se debe a que esta se hace de una forma muy similar a como se hizo en las simulaciones utilizadas durante el entrenamiento. La conexión únicamente presenta alguna pequeña diferencia en la velocidad a la que se realiza la conexión, una pequeña histéresis, y la red la absorbe sin inconvenientes.

La pérdida de red es el evento más diferente respecto de las simulaciones de entrenamiento y por tanto el que presenta mayor interés. Durante el entrenamiento las series temporales contienen pérdidas de red 2 y 6 segundos, mientras que la simulación para la validación tiene una duración de 4 segundos. Aquí es donde la red tiene que enfrentarse a condiciones distintas a las de entrenamiento. El patrón de control utilizado es el mismo para todas las simulaciones, de ahí que la desconexión por la pérdida de red se represente de manera análoga a como la hace en las simulaciones de entrenamiento. Durante la conexión es cuando la red tiene que responder a condiciones completamente nuevas y lo hace con bastante solvencia. Las primeras sobre oscilaciones son captadas, pero tiene una pequeña imprecisión en las amplitudes de estas, muestra unas amplitudes ligeramente superiores a las ofrecidas por las simulaciones. La nueva dinámica se representa pero con ciertas imperfecciones.

La parada de emergencia, al igual que ocurría con la conexión, tiene ligeras diferencias respecto a las simulaciones de entrenamiento, ya que aquí nuevamente impera la dinámica del control. Como la red captó correctamente su dinámica durante el entrenamiento, la parada se representa de manera análoga.

6 CONCLUSIONES

A la vista de los resultados obtenidos se puede afirmar que una red neuronal con las características apropiadas se puede considerar apta para captar la dinámica de las cargas que sufre un rodamiento en un una multiplicadora de aerogenerador tomando como partida los datos obtenidos de la simulación mecánica detallada del tren de potencia.

La representatividad de la dinámica captada por la red neuronal bajo nuevas condiciones de funcionamiento depende de cuánto estas condiciones se alejen de los eventos utilizados durante el entrenamiento.

Para eventos en los que las condiciones son similares a las de entrenamiento la red responde correctamente, sin embargo cuando las condiciones empiezan a ser distintas la red muestra resultados algo distintos, pero que se consideran aceptables dentro del marco del proyecto.

Como principales ventajas de esta modelización se pueden destacar:

- Capacidad para representar la dinámica no lineal del sistema.
- Capacidad de converger con un número de datos reducido.
- Capacidad de representar la dinámica interna con únicamente cuatro variables de entrada a la red, par y velocidad de rotor y par y velocidad de generador, que a su vez son accesibles en los modelos de simulación aeroelástica.
- Robustez para condiciones similares a las de entrenamiento.
- Sencillez de utilización de la red neuronal.
- Capacidad de computación, tiempo real.

Sin embargo también se han encontrado ciertas críticas.

- La escasa robustez de la red cuando los eventos difieren en gran medida respecto de los datos de entrenamiento, que principalmente se achaca a:
 - La escasa cantidad de datos utilizados para el entrenamiento. A posteriori destacar que se ha sido excesivamente restrictivo en este aspecto.
 - La gran variedad de puntos de operación de la turbina cuando el control de máquina utilizado no es el más apropiado.
- La gran dependencia de la fórmula de entrenamiento utilizada. El motivo de esta también está relacionado con los motivos anteriores.

Queda patente que con la metodología propuesta para captar la dinámica del sistema, las condiciones de operación está muy vinculada al control ejercido sobre el aerogenerador durante la simulación de los eventos de caracterización del sistema.

También queda patente que para poder englobar todas las posibles condiciones de operación por medio de una red neuronal son necesarias más simulaciones.

Por último se quiere concluir que debido a lo ambicioso de los objetivos iniciales, por medio de este trabajo se han querido establecer las bases para un posible desarrollo posterior donde las condiciones de operación sean evaluadas más minuciosamente con objeto de acotar el rango de puntos de operación en los que sea interesante que la red trabaje, en pro de obtener unos resultados más precisos y robustos.

Haciendo un balance entre la información disponible, las restricciones impuestas, algunas favorables como la reducción de puntos de operación a estudiar y otras no tanto, como el número tan reducido de datos de entrenamiento, los resultados obtenidos se consideran satisfactorios.

7 LINEAS DE INVESTIGACIÓN FUTURAS

Dado que el alcance inicial del proyecto se vio limitado y que queda patente que el campo de estudio sobre el que se ha realizado el presente trabajo es amplio, se presentan varias futuras vías de desarrollo.

Como primera futura vía de investigación, en la línea del trabajo realizado, se propone realizar una caracterización previa más concienzuda de las condiciones donde realmente va operar la máquina, para así acotar los puntos de operación y que las simulaciones detalladas de caracterización de cargas dinámicas también contemplen todos los puntos de operación posibles de todos los seleccionados previamente.

La utilización de modelos detallados acordes con el estado del arte actual también se considera como un requisito en futuras investigaciones, donde toda la dinámica del tren de potencia y más concretamente todas las no linealidades estén representadas. Se prevé que la respuesta dinámica se intensifique por lo que las redes neuronales tendrán que aumentar en complejidad para poder hacer frente al nuevo reto.

La extensión de las redes neuronales al resto de componentes de la multiplicadora, pensando principalmente en el resto de rodamientos. Esta metodología podría aplicarse a otros componentes del drive train o incluso a otros componentes de aerogenerador donde la modelización de estos no resulte abordable con técnicas convencionales.

La utilización de simulaciones a diferentes niveles de carga para poder representar con precisión el comportamiento de la máquina.

Dadas las capacidades de uso en tiempo real de las redes neuronales, la aplicación de estas como parte de las simulaciones aeroelásticas.

Se plantea una posible vía de desarrollo para la caracterización de la dinámica de la multiplicadora desde otro punto de vista, en el que las simulaciones utilizadas para caracterizar la dinámica externa sean específicas para ello. Reduciendo los grados de libertad a exclusivamente la multiplicadora con la consiguiente reducción de coste computación, en el que se realice un barrido de eventos como los realizados, pero a diferentes regímenes de funcionamiento.

Por último se plantea la utilización de datos reales de funcionamiento, como los que se puedan extraer de un banco de ensayo o de una máquina en campo, en lugar de datos provenientes de simulaciones. En este caso la red no podría ser usada en fases tempranas de diseño, pero si en fases posteriores.

8 REFERENCIAS

- [1] IEC 61400-1 Design requirements.
- [2] <http://www.nrel.gov/>
- [3] Applications of MATLAB in Science and Engineering, A Virtual Tool for Computer Aided Analysis of Spur Gears with Asymmetric Teeth, Fatih Karpat.
- [4] ISASI, P., GALVÁN, I. Redes de Neuronas Artificiales. Un enfoque práctico. Pearson Prentice Hall. Madrid, España. 2004. ISBN: 84-205-4025-0.
- [5] GODOY, M., MEIRELES, M., ALMEIDA, P. "A comprehensive review for industrial applicability of artificial neural networks". IEEE transactions on industrial electronics. 2003, vol. 50, p. 585-601.
- [6] McCULLOCH, W. y PITTS, W. "A logical calculus of the ideas immanent in nervous activity". Bulletin of Mathematical Biophysics, 1943, Vol. 9, p. 127-147.
- [7] HEBB, D. "The Organization of Behavior". New York: Wiley. 1949.
- [8] ROSENBLATT, F. "The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain". Psychological Review. 1958. Vol. 65, p. 386-408.
- [9] MINSKY, M., PAPERT, S. "Perceptrons". Cambridge, MA. MIT Press 1969.
- [10] KOHONEN, T. "Correlation Matrix Memories". IEEE Transactions on Computers. 1972. Vol. 21, p. 353-359.
- [11] GROSSBERG, S. "How does the brain build a cognitive code". Psychological Review. 1980. Vol. 88, p. 375-407.
- [12] HOPFIELD, J. "Neural network and Physical Systems with Emergent Collective Computational Abilities". Proceedings of the National Academy of Sciences. 1982. Vol. 79, p. 2554-2558.
- [13] HU Y., HWANG, J. "Handbook of Neural Network Signal Processing". CRC Press. ISBN 0849323592. EEUU, 2002.
- [14] <http://www.mathworks.com>
- [15] HERTZ J., KROGH A., PALMER R. "Introduction to the theory of neural computation". Addison-Wesley, 1991