

UNIVERSIDAD PONTIFICIA COMILLAS
ESCUELA TÉCNICA SUPERIOR DE INGENIERÍA (ICAI)
INGENIERO INDUSTRIAL



PROYECTO FIN DE CARRERA

**Desarrollo de indicadores para el pronóstico de la
condición de componentes de un aerogenerador.**

AUTOR: Guillermo Lázaro Martínez

DIRECTOR: Miguel Ángel Sanz Bobi

DIRECTOR: Miguel Ángel Rodríguez López

MADRID, 19 de septiembre del 2018

AUTORIZACIÓN PARA LA DIGITALIZACIÓN, DEPÓSITO Y DIVULGACIÓN EN RED DE PROYECTOS FIN DE GRADO, FIN DE MÁSTER, TESIS O MEMORIAS DE BACHILLERATO

1ª. Declaración de la autoría y acreditación de la misma.

El autor D. GUILLERMO LAZARO MARTINEZ

DECLARA ser el titular de los derechos de propiedad intelectual de la obra: DESARROLLO DE INDICADORES PARA EL PRONÓSTICO DE LA CONDICIÓN DE UN AERO GENERADOR que ésta es una obra original, y que ostenta la condición de autor en el sentido que otorga la Ley de Propiedad Intelectual.

2ª. Objeto y fines de la cesión.

Con el fin de dar la máxima difusión a la obra citada a través del Repositorio institucional de la Universidad, el autor CEDE a la Universidad Pontificia Comillas, de forma gratuita y no exclusiva, por el máximo plazo legal y con ámbito universal, los derechos de digitalización, de archivo, de reproducción, de distribución y de comunicación pública, incluido el derecho de puesta a disposición electrónica, tal y como se describen en la Ley de Propiedad Intelectual. El derecho de transformación se cede a los únicos efectos de lo dispuesto en la letra a) del apartado siguiente.

3ª. Condiciones de la cesión y acceso

Sin perjuicio de la titularidad de la obra, que sigue correspondiendo a su autor, la cesión de derechos contemplada en esta licencia habilita para:

- Transformarla con el fin de adaptarla a cualquier tecnología que permita incorporarla a internet y hacerla accesible; incorporar metadatos para realizar el registro de la obra e incorporar "marcas de agua" o cualquier otro sistema de seguridad o de protección.
- Reproducirla en un soporte digital para su incorporación a una base de datos electrónica, incluyendo el derecho de reproducir y almacenar la obra en servidores, a los efectos de garantizar su seguridad, conservación y preservar el formato.
- Comunicarla, por defecto, a través de un archivo institucional abierto, accesible de modo libre y gratuito a través de internet.
- Cualquier otra forma de acceso (restringido, embargado, cerrado) deberá solicitarse expresamente y obedecer a causas justificadas.
- Asignar por defecto a estos trabajos una licencia Creative Commons.
- Asignar por defecto a estos trabajos un HANDLE (URL persistente).

4ª. Derechos del autor.

El autor, en tanto que titular de una obra tiene derecho a:

- Que la Universidad identifique claramente su nombre como autor de la misma.
- Comunicar y dar publicidad a la obra en la versión que ceda y en otras posteriores a través de cualquier medio.
- Solicitar la retirada de la obra del repositorio por causa justificada.
- Recibir notificación fehaciente de cualquier reclamación que puedan formular terceras personas en relación con la obra y, en particular, de reclamaciones relativas a los derechos de propiedad intelectual sobre ella.

5ª. Deberes del autor.

El autor se compromete a:

- Garantizar que el compromiso que adquiere mediante el presente escrito no infringe ningún derecho de terceros, ya sean de propiedad industrial, intelectual o cualquier otro.
- Garantizar que el contenido de las obras no atenta contra los derechos al honor, a la intimidad y a la imagen de terceros.
- Asumir toda reclamación o responsabilidad, incluyendo las indemnizaciones por daños, que pudieran ejercitarse contra la Universidad por terceros que vieran infringidos sus derechos e

intereses a causa de la cesión.

- d) Asumir la responsabilidad en el caso de que las instituciones fueran condenadas por infracción de derechos derivada de las obras objeto de la cesión.

6ª. Fines y funcionamiento del Repositorio Institucional.

La obra se pondrá a disposición de los usuarios para que hagan de ella un uso justo y respetuoso con los derechos del autor, según lo permitido por la legislación aplicable, y con fines de estudio, investigación, o cualquier otro fin lícito. Con dicha finalidad, la Universidad asume los siguientes deberes y se reserva las siguientes facultades:

- La Universidad informará a los usuarios del archivo sobre los usos permitidos, y no garantiza ni asume responsabilidad alguna por otras formas en que los usuarios hagan un uso posterior de las obras no conforme con la legislación vigente. El uso posterior, más allá de la copia privada, requerirá que se cite la fuente y se reconozca la autoría, que no se obtenga beneficio comercial, y que no se realicen obras derivadas.
- La Universidad no revisará el contenido de las obras, que en todo caso permanecerá bajo la responsabilidad exclusiva del autor y no estará obligada a ejercitar acciones legales en nombre del autor en el supuesto de infracciones a derechos de propiedad intelectual derivados del depósito y archivo de las obras. El autor renuncia a cualquier reclamación frente a la Universidad por las formas no ajustadas a la legislación vigente en que los usuarios hagan uso de las obras.
- La Universidad adoptará las medidas necesarias para la preservación de la obra en un futuro.
- La Universidad se reserva la facultad de retirar la obra, previa notificación al autor, en supuestos suficientemente justificados, o en caso de reclamaciones de terceros.

Madrid, a 13 de septiembre de 2018

ACEPTA

Fdo. 

Motivos para solicitar el acceso restringido, cerrado o embargado del trabajo en el Repositorio Institucional:

Declaro, bajo mi responsabilidad, que el Proyecto presentado con el título
DESARROLLO DE INDICADORES PARA EL PRONÓSTICO
DE LA CONDICIÓN DE COMPONENTES DE UN AEROGENERADOR

en la ETS de Ingeniería - ICAI de la Universidad Pontificia Comillas en el
curso académico 2017-2018 es de mi autoría, original e inédito y
no ha sido presentado con anterioridad a otros efectos. El Proyecto no es
plagio de otro, ni total ni parcialmente y la información que ha sido tomada
de otros documentos está debidamente referenciada.

Fdo.: Guillermo Lázaro Martínez

Fecha: 13 / 09 / 2018



Autorizada la entrega del proyecto

EL DIRECTOR DEL PROYECTO

Fdo.: José María Sáenz

Fecha: 17 / 09 / 2018

Fdo.: Miguel Ángel Rodríguez López

Fecha: 14 / 09 / 2018

Resumen

1. Introducción

Hoy en día, el uso de energías crece continuamente al igual que la demanda, la cual debe ser satisfecha. La generación de energía utilizando materias fósiles, aumenta la contaminación provocando el calentamiento global. Para resolver este inconveniente, se apostó por el uso de energías renovables, siendo la energía eólica la que tuvo mayor evolución según esta gráfica sacados del artículo [1].




Figura 1. Capacidad de generación de electricidad, EU-28, 1990-2014

La contribución de la energía eléctrica es importante para limitar el uso de combustibles fósiles. Esto hace necesario minimizar el impacto de posibles indisponibilidades de los aerogeneradores debido a su importancia en la generación eléctrica. El fallo o pérdida de un aerogenerador supone unos costes tanto de energía no producida, como de mantenimiento, que en la medida de lo posible es conveniente minimizar. Por eso se debería analizar si es posible anticiparse a momentos de cierto riesgo de fallo en base al historial de incidencias que ha habido.

El objetivo de este proyecto de fin de grado es utilizar la información de seguimiento de un aerogenerador real para la detección de anomalías de algunos de sus componentes tales como multiplicadora, generador eléctrico y control de paso de pala y proponer indicadores de su estado de salud, así como realizar un pronóstico sobre su posible evolución a corto plazo. La detección de anomalías se basará en la caracterización de modelos de comportamiento normal.


El coste de mantenimiento de un aerogenerador es lo suficiente impactante como para generar la necesidad de monitorizar e investigar nuevos métodos para detectar y

diagnosticar las distintas anomalías que presenta un aerogenerador. Es por eso por lo que ya se han utilizado diferentes herramientas para hacer una prognosis, es decir, una predicción del funcionamiento de un aerogenerador a corto o medio plazo con el fin de mejorar su mantenimiento.


2. Metodología de trabajo

La metodología del proyecto seguirá los siguientes esquemas:

Creación del modelo de comportamiento normal:



Detección de anomalías:



Lo primero que hay que hacer consiste en filtrar los datos defectuosos, ya sea porque son NAN (not a number), los datos son negativos en valores absolutos, o que se identifique como valores que no son posibles o esperados para el aerogenerador.

Una vez filtrado todos los valores no utilizables, se empezará a realizar los modelos utilizando los datos de entrenamiento. El estudio del comportamiento del aerogenerador se hará a partir de tres componentes: el generador, la multiplicadora y el paso de pala. El estudio del generador se hizo a partir de la temperatura del anillo y de los rodamientos (un modelo para el rodamiento DE y otro para el rodamiento NDE); el de la multiplicadora se hará a partir de la temperatura del aceite de la multiplicadora y la del rodamiento de esta; y el estudio del paso de pala se hará a partir del ángulo de estas. En total habrá seis modelos a estudiar. El rodamiento DE significa ‘driving end’ y es aquel rodamiento del generador que está situado en el lado del eje motriz del rodamiento mientras que el rodamiento NDE significa ‘non-driving end’ y es el que se sitúa en el otro lado.

Estos modelos se desarrollarán utilizando métodos de aprendizaje automático como las redes neuronales (perceptrón multicapa y RBF) y las máquinas de soporte vectorial (SVM). Se probará como funcionan de forma individual y posteriormente se analizará su funcionamiento en un futuro.

Los datos de entrenamiento escogidos serán los correspondientes a 2010, quitando los que se tuvieron que filtrar debido a problemas como mal funcionamiento del sensor y valores nulos. Estos datos se utilizarán para generar los modelos de funcionamiento normal y con ellos se formará un patrón de funcionamiento del aerogenerador. A partir

de ese modelo se utilizarán datos medidos posteriormente: 2011, 2012, 2013 y 2014, y se estudiará la probabilidad de que los datos reales entren en las bandas de confianza, las cuales suponen un comportamiento normal. Si entra, se supone un funcionamiento correcto y si no entra, se tratará de una posible anomalía a estudiar.

Una vez hecho eso, se propondrán nuevos indicadores del estado de salud del aerogenerador basándonos en los modelos de funcionamiento obtenidos.

3. Conclusiones

Las anomalías que se presentan por día en cada componente se presentan en las siguientes gráficas:




Figura 2. Decisión final. Representación del número de anomalías por día. Modelo del generador




Figura 3. Representación del número de anomalías por día. Modelo de la multiplicadora




Figura 4. Representación del número de anomalías por día. Modelo del paso de pala

Gracias a los resultados obtenidos habrá una mejor planificación del mantenimiento del aerogenerador.

Summary

1. Introducción

Nowadays, the use of energies grows continuously throughout the demand, which must be satisfied. The generation of energy using fossil materials increases pollution causing global warming. To solve this problem, we opted for the use of renewable energies, energy being the one with the highest evolution according to this graph, taken from EUROSAT.




Figure 1. Electricity generation capacity, EU-28, 1990-2014

The contribution of electric power is important to limit the use of fossil fuels. This makes it necessary to minimize the impact of possible unavailability of wind turbines due to their importance in electricity generation. The failure or loss of a wind turbine involves costs of both non-produced energy and maintenance, which as far as possible is convenient to minimize. Therefore, it should be analyzed if it is possible to anticipate moments of certain risk of failure based on the history of incidents that have occurred.

The objective of this final degree project is to use the monitoring information of a real wind turbine for the detection of anomalies of some of its components such as multiplier, electric generator and blade pitch control and propose indicators of their health status, as well as making a forecast about its possible short-term evolution. The detection of anomalies will be based on the characterization of normal behavior models.


The maintenance cost of a wind turbine is sufficiently impressive to generate the need to monitor and investigate new methods to detect and diagnose the different

anomalies that a wind turbine presents. That is why they have already used different tools to make a prognosis, that is, a prediction of the operation of a wind turbine in the short or medium term in order to improve its maintenance.


2. Metodología de trabajo

The methodology of the project will follow the following scheme:

Creation of the normal behavior model:



Detection of anomalies:



The first thing to do is to filter the defective data, either because they are NAN (not a number), the data are negative in absolute values, or they are identified as values that are not possible or expected for the wind turbine.

Once all the unusable values have been filtered, you will start to make the models using the training data. The study of the wind turbine behavior will be made from three components: the generator, the multiplier and the blade pitch. The generator was studied based on the temperature of the ring and the bearings (one model for the DE bearing and another for the NDE bearing); the multiplier will be made from the oil temperature of the gearbox and the bearing of the same; and the study of the blade pitch will be made from the angle of the same. In total there will be six models to study. The DE bearing means 'driving end' and it's that generator bearing that is located on the drive shaft side of the bearing while the NDE bearing mean 'non-driving end' and it's the one on the other side.

These models will be developed using automatic learning methods such as neural networks (multilayer perceptron and RBF) and vector support machines (SVM). It will be tested how they work individually and later their operation will be analyzed in the future.

The training data chosen will be those corresponding to 2010, removing those that had to be filtered due to problems such as sensor malfunction and null values. These data will be used to generate the models of normal operation and with them a pattern of operation of the wind turbine will be formed. From this model, data data measured later will be used: 2011, 2012, 2013 and 2014, and the probability that the real data will enter the confidence bands, which suppose a normal behavior, will be studied. If it enters, it assumes a correct operation and if it does not enter, it will be a possible anomaly to study.

Once that is done, new indicators of the health status of the wind turbine will be proposed based on the operating models obtained.

3. Conclusions

The anomalies that occur per day in each component are presented in the following graphs:




Figure 2. Representation of the number of anomalies per day. Generator model




Figure 3. Representation of the number of anomalies per day. Model of the multiplier




Figure 4. Final decision. Representation of the number of anomalies per day. Shovel step model

Thanks to the results obtained there will be a better planning of the maintenance of the wind turbine.

Índice

1. Estado del arte	
1.1. Modelos.....	19
1.2. Motivación	20
1.3. Objetivos del proyecto	21
1.4. Recursos a emplear	21
2. Variables a utilizar	
2.1. Descripción de modelos	24
3. Esquema lógico de realización	
4. Prefiltrado de datos	
4.1. Primeros pasos	28
4.2. Primer filtrado	28
4.3. Segundo filtrado	29
4.4. Elección de datos de entrenamiento.....	30
5. Modelo de comportamiento normal basado en una red neuronal perceptrón multicapa	
5.1. Modelo de comportamiento normal del generador	32
5.2. Modelo de comportamiento normal de la multiplicadora	38
5.3. Modelo de comportamiento normal del control del paso de pala	42
5.4. Conclusiones	45
6. Modelo de comportamiento normal basado en una red neuronal RBF	
6.1. Modelo de comportamiento normal del generador	47
6.2. Modelo de comportamiento normal de la multiplicadora	53
6.3. Modelo de comportamiento normal del control del paso de pala	58
6.4. Conclusiones	59
7. Modelo de comportamiento normal basado en la máquina de soporte vectorial (SVM)	
7.1. Modelo de comportamiento normal del generador	61
7.2. Modelo de comportamiento normal de la multiplicadora	67
7.3. Modelo de comportamiento normal del control del paso de pala	71
7.4. Conclusiones	73
8. Comparación de modelos de comportamiento normal	
8.1. Conclusiones	75
9. Detección de anomalías	
9.1. Utilizando el modelo de comportamiento normal de la red neuronal perceptrón multicapa.....	77

9.2. Utilizando el modelo de comportamiento normal de la red neuronal RBF	89
9.3. Utilizando el modelo de comportamiento normal de la máquina de soporte vectorial (SVM)	101
9.4. Utilizando todos los modelos de comportamiento	113
9.5. Conclusiones	137
10. Comparación estadística de los detectores	
10.1. Año 2011	138
10.2. Año 2012	139
10.3. Año 2013	139
10.4. Año 2014	140
10.5. Conclusiones	140
11. Indicadores de comportamiento anómalos	
11.1. Utilizando el modelo de comportamiento normal de la red neuronal perceptrón multicapa	142
11.2. Utilizando el modelo de comportamiento normal de la red neuronal RBF	146
11.3. Utilizando el modelo de comportamiento normal del SVM	150
11.4. Utilizando todos los modelos basados en las distintas herramientas de aprendizaje automatizado. Decisión final ...	154
11.5. Índice de anomalías por unidad de tiempo	158
11.6. Conclusiones	161
12. Conclusión	
Bibliografía	
Anexos	

Capítulo 1

Estado del arte

La energía eólica presentó un gran crecimiento respecto al resto de energías renovables durante estos últimos años como ya se comentó anteriormente. El coste de mantenimiento de un aerogenerador es lo suficiente impactante como para generar la necesidad de monitorizar e investigar nuevos métodos para detectar y diagnosticar las distintas anomalías que presenta un aerogenerador. Es por eso por lo que ya se han utilizado diferentes herramientas para hacer una prognosis, es decir, una predicción del funcionamiento de un aerogenerador a corto o medio plazo con el fin de mejorar su mantenimiento.

1.1 Modelos

Los modelos de comportamiento normal que indicarán el estado de salud del aerogenerador son los siguientes:

-Modelo de comportamiento normal de la multiplicadora: El rendimiento total del aerogenerador corresponde en gran parte a la multiplicadora. A su vez, la función principal de la multiplicadora consiste en transformar las bajas revoluciones de giro del buje del aerogenerador en las altas revoluciones que necesita el generador para producir energía. Por lo tanto, la multiplicadora debe estar en perfectas condiciones. La solución que se ha implementado hasta ahora ha sido básicamente cambiar y mejorar la multiplicadora. Una de las soluciones fue mejorar la lubricación de la multiplicadora, lo cual consiguió mejorar el rendimiento del aerogenerador ya que disminuyó el rozamiento de los engranajes. La otra solución fue implementar la multiplicadora hasta la de tipo planetario, cuyas características son: alta relación de transformación, varias multiplicaciones (lo cual permite trabajar en caso de que trabaje con distintas velocidades angulares), menor espacio de trabajo y puede soportar mayores cargas. Esta es una multiplicadora de tipo planetario. Se habla con más detalle sobre la multiplicadora en el artículo [2].




Figura 5. Multiplicadora de tipo planetario

-Modelo de comportamiento normal del generador eléctrico: El generador eléctrico convierte la energía mecánica del par de torsión del aerogenerador en energía eléctrica. A lo largo de la historia se han utilizado tres tipos de generadores eléctricos en los aerogeneradores: generador de corriente continua, generador de corriente alterna síncrono y generador de corriente alterna asíncrono. En principio todos pueden funcionar a velocidad fija o variable, pero es preferible trabajar a velocidad variable ya que reduciría el estrés de las palas debido a la naturaleza fluctuante de la energía del viento. Una implementación que se puede hacer de los generadores sería mejorando el sistema de enfriamiento, el cual hay dos opciones posibles dependiendo del fabricante: refrigeración por aire y refrigeración por agua. Se habla sobre el generador de un aerogenerador en el artículo [3]

-Modelo de comportamiento normal del control de paso de pala: Las palas son elementos que capturan la energía del viento y transmiten su potencia hasta el buje. Hay dos tipos de pala: las palas de paso fijo, cuya posición permanece invariable lo cual tiene una gran desventaja, en la que si se excede la velocidad del viento a un determinado valor sería necesario limitar la energía capturada, produciendo graves pérdidas aerodinámicas; y, las palas de paso variable modifican el ángulo del perfil de la pala respecto a la velocidad del viento, lo que permitiría adaptarse ante cambios atmosféricos. Se habla sobre los tipos de paso de pala en el artículo [4].

1.2 Motivación

Con el desarrollo de este proyecto, se pretende realizar un estudio que permita realizar un pronóstico sobre la evolución de un aerogenerador a corto plazo. De esta manera, se podrían detectar ciertas anomalías en alguno de sus componentes con el fin de proponer indicadores en su estado de salud y poder evitar la indisponibilidad del propio aerogenerador.

La energía eólica fue en el año 2017 la segunda fuente de energía eléctrica con más potencia eléctrica generada en España, con una producción de 47886 GWh y una cobertura de la demanda eléctrica del 18.4 %. datos proporcionados por la AEE (Asociación Empresarial Eólica) en el artículo [5]. Es por eso por lo que la indisposición de algunos generadores podría generar un gran impacto para la satisfacción de la demanda

en España.

Por último, este estudio facilitaría el mantenimiento de los aerogeneradores. Permitirá a las empresas encargadas de producir energía eléctrica ahorrar las pérdidas que tendrían debido a la posible indisponibilidad de sus equipos.

1.3 Objetivos del proyecto

Las metas planteadas para la realización del proyecto son las siguientes:

1. Desarrollo de modelos de comportamientos normal basados en máquinas de soporte virtual, redes neuronales del tipo perceptrón multicapa y redes neuronales de base radial (RBF). Se prevé el desarrollo de una estructura híbrida de modelos de comportamiento normal.
2. Proponer una arquitectura compleja de modelos de comportamiento normal para detectar anomalías en los principales componentes de un aerogenerador.
3. Se propondrán nuevos indicadores del estado de salud del aerogenerador basados en los modelos obtenidos.
4. Se estudiarán los resultados de esta metodología de cara a su aplicación en el futuro.

El proceso de investigación de la detección de anomalías de un aerogenerador está explicado con mayor detalle en el artículo [6].

1.4 Recursos a emplear

El proyecto se desarrollará utilizando MATLAB y algoritmos de aprendizaje automático tales como redes neuronales (NN) (perceptrón multicapa y RBF) y máquinas de soporte virtual(SVM).

Redes neuronales (NN):

- a) Se han hecho los ajustes con redes neuronales perceptrón multicapa. Estos permitirán resolver problemas que nos son linealmente separables. En términos genéricos, cada salida de la capa i supone la entrada de la capa $i + 1$.




Figura 6. Ejemplo genérico de red neuronal perceptrón multicapa.

Los tipos de capa se clasifican en:

-*Capas de entrada*: Introducen los patrones de entrada a la red.

-*Capas ocultas*: Sus entradas provienen de capas anteriores y sus salidas serán entradas de capas posteriores.

-*Capa de salida*: Sus valores de salida corresponden al valor de salida de toda la red. En el artículo [7] se trata el tema de estas redes neuronales.

- b) También se harán los ajustes con redes neuronales con base radial (RBF). [6] Se caracterizan por tener un aprendizaje híbrido. Al igual que el perceptrón multicapa las capas se clasifican por capa de entrada, capa oculta o capa de salida.




Figura 7. Ejemplo genérico de red neuronal RBF

Aunque la estructura se pueda parecer a la red neuronal perceptrón multicapa, se

diferencia en que el perceptrón multicapa calcula la suma ponderada de las variables de entrada y se le aplica una sigmoide mientras que al utilizar la red neuronal RBF se calcula la distancia euclidiana entre las variables de entrada y el peso sináptico y se le aplica una función radial de tipo gaussiana. En el artículo [8] se trata el tema de estas redes neuronales.

Máquinas de vectores soporte (SVM): Consiste en un conjunto de algoritmo de aprendizaje supervisado, es decir, se necesitan datos esperados, de esta forma se podrá conseguir el comportamiento normal. Dado un punto o un conjunto de puntos en el que cada punto pertenece a una de dos posibles categorías, un algoritmo basado en máquinas virtuales (SVM), construye un modelo capaz de predecir si un punto nuevo pertenece a una categoría o a la otra. En el artículo [9] se habla de las máquinas de soporte vectoriales.

Capítulo 2

Variables a utilizar

Para la realización del proyecto se ha decidido estudiar un modelo de aerogenerador tripala de 2 MW. De su sistema de seguimiento se han extraído 32 variables actualizadas cada 10 minutos desde el día 15 de diciembre de 2018 hasta el 7 de septiembre de 2014, que son exactamente 291312 datos por variable.

Dichas variables monitorean en tiempo real distintas características de sus componentes, lo cual facilita conocer la fiabilidad de algunos de los componentes para prever su funcionamiento.

A continuación, se explica los modelos que se creará en cada uno de los controles y la decisión de las variables que se van a emplear en cada uno.

2.1 Descripción de modelos

1. Modelos de comportamiento normal del generador:

-Modelo de comportamiento normal de los anillos del generador: Para este control se utilizará como variable de entrada: la temperatura de los anillos del generador; y las variables de salida serán: la temperatura del interior de la góndola*, la potencia total que produce el generador y la velocidad del viento.

-Modelo de comportamiento normal del rodamiento DE del generador: Para este control se utilizará como variable de entrada: la temperatura del rodamiento DE del generador; y las variables de salida serán: la temperatura del interior de la góndola*, la potencia total que produce el generador y la velocidad del viento.

-Modelo de comportamiento normal del rodamiento NDE del generador: Para este control se utilizará como variable de entrada: la temperatura del rodamiento NDE del generador; y las variables de salida serán: la temperatura del interior de la góndola, la potencia total que produce el generador y la velocidad del viento.

2. Modelos de comportamiento normal de la multiplicadora:

-Modelo de comportamiento normal de la temperatura del aceite de la multiplicadora: Para este control se utilizará como variable de entrada: la temperatura del aceite de la multiplicadora; y las variables de salida serán: la temperatura del interior de la góndola*, la potencia total que produce el generador y la velocidad del viento.

-Modelo de comportamiento normal del rodamiento de la multiplicadora: Para este control se utilizará como variable de entrada: la temperatura del rodamiento de la multiplicadora; y las variables de salida serán: la temperatura del interior de la góndola*, la potencia total que produce el generador y la velocidad del viento.

3. Modelo de comportamiento normal del paso de pala:

-Modelo de comportamiento normal del paso de pala: Para este control se utilizará como variable de entrada: el ángulo de las palas; y las variables de salida serán: la velocidad del viento, la potencia total que produce el generador y el ángulo del viento.

Como se puede observar, en total se trabajará con 6 controles y las siguientes variables: la temperatura de los anillos del generador, la temperatura del rodamiento DE del generador, la temperatura del rodamiento NDE del generador, la temperatura del aceite de la multiplicadora, la temperatura del rodamiento de la multiplicadora, el ángulo de las palas, la temperatura del interior de la góndola, la potencia total que produce el generador, la velocidad del viento y el ángulo del viento. Por lo tanto, de las 32 variables disponibles, necesitaremos 10 variables.

La góndola o nacelle se trata del compartimento en donde está alojado tanto la multiplicadora como el generador del aerogenerador. A continuación, se mostrará una imagen de la góndola.





Figura 8. Imagen descriptiva de la góndola o nacelle

Capítulo 3

Esquema lógico de realización del proyecto


En este capítulo se mostrará un esquema que sirve como un pequeño resumen que explicará el procedimiento de realización del Proyecto.

Creación del modelo de comportamiento normal:



Como se puede ver en el esquema, esta primera parte consiste en el tratamiento del conjunto de entrenamiento, aquellos datos a partir de los cuales se creará el modelo. Estos datos de entrenamiento se utilizarán para crear sus modelos de comportamiento normal basados tanto en las redes neuronales como en las máquinas de vectores soporte (SVM). Esta parte estará más desarrollada en el apartado correspondiente.

Detección de anomalías:



Una vez creados los modelos de comportamiento normal, se procede a realizar la detección de anomalías. Para ello se utilizan los modelos obtenidos para obtener una simulación de los valores de cada una de las componentes. A partir de dicha simulación, se obtendrá unas bandas de confianza donde se estudiará la probabilidad de que los valores reales correspondan a un comportamiento normal. Se explicará este proceso con más detenimiento en apartados posteriores.

Capítulo 4

Prefiltrado de datos

4.1 Primeros pasos

Como ya se comentó anteriormente, se dispone de 32 variables, actualizados cada 10 minutos desde finales del año 2018 hasta finales de 2014. En cada variable habrá un total de 291312 datos, los cuales necesitarán reducirse haciendo un filtrado.

El filtrado de datos es muy necesario, porque nos permite eliminar esas variables innecesarias, por un lado, se eliminarán las variables negativas que deben ser positivas, ya que se trata de valores absolutos. Por otro lado, se eliminarán los datos NAN (Not a Number). Todos esos datos son necesarios de eliminar ya que se supone que están debido a un error del detector.

Este filtrado inicial se realiza utilizando un código de Matlab utilizando un bucle for para que se pueda pasar por todos los datos de la matriz de variables; y una función if, en la cual se pondrán las condiciones de las variables.

En este filtrado, cada variable pasará de los 291312 datos ya mencionados a 3649. Como con este filtrado se pierde una gran cantidad de datos (en mayor parte, los datos obtenidos son del 2009 al 2010), se descarta este filtrado. Por lo tanto, habrá que utilizar otro criterio para realizar el filtrado.

4.2 Primer filtrado

Como filtrar utilizando todas las variables no nos aporta demasiados datos para realizar el estudio, se decidió realizar un filtrado con las 10 variables que se utilizarán. Este filtrado se realizará usando el mismo método que en el apartado anterior, con la diferencia de que se ha decidido dividir en 6 partes, una por cada año (2008/2009, 2010, 2011, 2012, 2013 y 2014).

Los datos del 2009 y los del 2010 son los principales candidatos para ser los datos de entrenamiento debido a que son los primeros datos que se han medido y por lo tanto habrá menos desgaste en los componentes. Por lo tanto, se han utilizado los datos antes mencionados para el aprendizaje tanto de las redes neuronales como de las máquinas de soporte vectorial. Como en las gráficas se pueden observar picos que serán fallos en la medida del detector, se decidió proceder a realizar un segundo filtrado en el cual se añadirá un rango en el cual solo se aceptarán los datos que estén dentro de ese rango.

Las gráficas resultantes de este primer filtrado se encuentran en el Anexo I.

4.3 Segundo filtrado

Para evitar que haya datos provocados por errores, se añadirá un rango de valores en cada variable. Dichos rangos serán los siguientes:

- Temperatura del rodamiento de la multiplicadora: Sus valores se encontrarán entre 55 y 80.

- Temperatura del aceite de la multiplicadora: Sus valores se encontrarán entre 45 y 75.

- Temperatura del rodamiento DE del generador: Sus valores se encontrarán entre 25 y 60.

- Temperatura del rodamiento NDE del generador: Sus valores se encontrarán entre 25 y 60.

- Temperatura de los anillos del generador: Sus valores se encontrarán entre 5 y 30.

- Temperatura del interior de la góndola: No se añadirá ningún intervalo extra.

- Potencia total generada: No se añadirá ningún intervalo extra.

- Velocidad del viento: No se añadirá ningún intervalo extra.

- Ángulo de las palas: Sus valores se encontrarán entre 0 y 45. A 45 grados es cuando mejor aprovecha el flujo del viento.

- Ángulo del viento: Sus valores se encontrarán entre -45 y 45.

Como se puede observar en las gráficas, las cuales se encuentran en el Anexo II, se reduce la cantidad de picos y valores ‘extraños’. Aunque todavía hay algún pico, si se filtrasen más los datos que tenemos sería falsear el estudio y por lo tanto no sería recomendable.

Los códigos utilizados para realizar este filtrado se encuentran en el Anexo III.

4.4 Elección de datos de entrenamiento

Al terminar este filtrado, nos encontramos que, en el 2009, los datos que obtenemos en cada variable son 3397 en total; mientras que en el 2010 hay un total de 51515 datos en cada variable. Debido a ello, se ha decidido utilizar los datos obtenidos en el año 2010 como datos de entrenamiento en vez de los obtenidos en el 2009. Aunque estos datos están más envejecidos y por lo tanto su funcionamiento es menos fiable, al haber mayor número de datos, las redes neuronales y la máquina de soporte virtual tendrá más valores para aprender. La otra desventaja será que no tendremos el año de 2010 como valores desconocidos y se hará el detector de anomalías a partir del año 2011.

Capítulo 5

Modelo de comportamiento normal basado en el uso de una red neuronal perceptrón multicapa

Como se explicó anteriormente, los datos de entrenamiento escogidos son aquellos que datan el 2011. Eso es debido a que hay una gran diferencia entre la cantidad de datos filtrados del 2009 (3397) y aquellos filtrados en el 2010 (51515). Al haber más datos del 2010 que en el 2009, el modelo de comportamiento normal será a priori mejor ya que habrá más datos para aprender.

En esta primera parte, se utilizará como método de aprendizaje automático, una red neuronal perceptrón multicapa. Este tipo de modelo, ideado por Minsky y Papert en 1969, resuelve problemas no lineales, los cuales no podía resolver el perceptrón simple. Este tipo de arquitectura se creó con la combinación de varios perceptrones simples (de una capa). Como se comentó, en el artículo [7] se habla de este tema.

Para la creación de los modelos de este estudio, se utilizó la función feedforwardnet. Los respectivos códigos se pueden ver en el Anexo IV.

Para crear cada uno de los modelos, se utilizará la elección de variables que se mencionó anteriormente. Así, se podrá diferenciar los subcomponentes asignados a cada componente del cual se pretende crear su modelo de comportamiento normal: Modelo del generador (temperatura de los anillos del generador y temperatura de los rodamientos DE y NDE del generador); modelo del multiplicador (temperatura del aceite de la multiplicadora y la temperatura del rodamiento de la multiplicadora).


A continuación, se explicarán las características de cada modelo de funcionamiento normal utilizado.

5.1 Modelo de comportamiento normal del generador

Para realizar el modelo de comportamiento del generador, el conjunto de entrenamiento se escogerá de los siguientes subcomponentes: los anillos del generador y los rodamientos de este (tanto DE cómo NDE).

-Modelo de comportamiento normal de los anillos del generador

Para realizar este modelo de comportamiento, la variable de salida será la temperatura de los anillos del generador y las variables de entrada son las siguientes: temperatura del interior de la nacelle, la potencia total generada y la velocidad del viento. Este es el modelo con sus entradas y salidas:



Primero, se verá una representación del número de capas y el número de neuronas usados:




Figura 9. Modelo de la red neuronal perceptrón multicapa. Arquitectura interna de la red neuronal en el modelo de los anillos del generador

A continuación, se mostrará la gráfica en la cual se ve el seguimiento del modelo utilizando el conjunto de entrenamiento (los datos que se han usado para crear el modelo). Esta gráfica compara el valor estimado con el valor real.




Figura 10. Modelo de la red neuronal perceptrón multicapa. Comportamiento de la temperatura de los anillos del generador con datos de entrenamiento. Gráficas comparativas de los valores simulados con los valores reales

Ahora se mostrará el histograma que muestra el error del modelo comparando los valores reales con el simulado.





Figura 11. Modelo de la red neuronal perceptrón multicapa. Comportamiento de la temperatura de los anillos del generador con datos de entrenamiento. Histograma gaussiano del error del modelo

El histograma muestra los errores de seguimiento del modelo de comportamiento normal utilizando el conjunto de entrenamiento con los valores reales. Como se puede observar, la gráfica muestra una gaussiana cuyo centro de gravedad es aproximadamente 0, por lo tanto, la media se puede despreciar. A continuación, se mostrarán los valores estadísticos más importantes para este estudio, es decir, la media, la desviación típica y el error cuadrático medio (MSE):

- Media: $5.4423 \cdot 10^{-4}$
- Desviación típica: 1.9351
- MSE: 3.7746

-Modelo de comportamiento normal del rodamiento DE del generador

Para realizar este modelo de comportamiento, la variable de salida será la temperatura del rodamiento DE del generador y las variables de entrada son las siguientes: temperatura del interior de la nacelle, la potencia total generada y la velocidad del viento. Este es el modelo con sus entradas y salidas:



Primero, se verá una representación del número de capas y el número de neuronas usados:




Figura 12. Modelo de la red neuronal perceptrón multicapa. Arquitectura interna de la red neuronal en el modelo del rodamiento DE del generador

A continuación, se mostrará la gráfica en la cual se ve el seguimiento del modelo utilizando el conjunto de entrenamiento (los datos que se han usado para crear el modelo).

Esta gráfica compara el valor estimado con el valor real.




Figura 13. Modelo de la red neuronal perceptrón multicapa. Comportamiento de la temperatura del rodamiento DE del generador con datos de entrenamiento. Gráficas comparativas de los valores simulados con los valores reales

Ahora se mostrará el histograma que muestra el error del modelo comparando los valores reales con el simulado.





Figura 14. Modelo de la red neuronal perceptrón multicapa. Comportamiento de la temperatura del rodamiento DE del generador con datos de entrenamiento. Histograma gaussiano del error del modelo

El histograma muestra los errores de seguimiento del modelo de comportamiento normal utilizando el conjunto de entrenamiento con los valores reales. Como se puede observar, la gráfica muestra una gaussiana cuyo centro de gravedad es aproximadamente 0, por lo tanto, la media se puede despreciar. A continuación, se mostrarán los valores estadísticos más importantes para este estudio, es decir, la media, la desviación típica y el error cuadrático medio (MSE):

- Media: 0.0770
- Desviación típica: 2.7397
- MSE: 7.5119

-Modelo de comportamiento normal del rodamiento NDE del generador

Para realizar este modelo de comportamiento, la variable de salida será la temperatura del rodamiento NDE del generador y las variables de entrada son las siguientes: temperatura del interior de la nacelle, la potencia total generada y la velocidad del viento. Este es el modelo con sus entradas y salidas:



Primero, se verá una representación del número de capas y el número de neuronas usados:




Figura 15. Modelo de la red neuronal perceptrón multicapa. Arquitectura interna de la red neuronal en el modelo del rodamiento NDE del generador

A continuación, se mostrará la gráfica en la cual se ve el seguimiento del modelo utilizando el conjunto de entrenamiento (los datos que se han usado para crear el modelo). Esta gráfica compara el valor estimado con el valor real.




Figura 16. Modelo de la red neuronal perceptrón multicapa. Comportamiento de la temperatura del rodamiento NDE del generador con datos de entrenamiento. Gráficas comparativas de los valores simulados con los valores reales

Ahora se mostrará el histograma que muestra el error del modelo comparando los valores reales con el simulado.



Figura 17. Modelo de la red neuronal perceptrón multicapa. Comportamiento de la temperatura del rodamiento NDE del generador con datos de entrenamiento. Histograma gaussiano del error del modelo

El histograma muestra los errores de seguimiento del modelo de comportamiento normal utilizando el conjunto de entrenamiento con los valores reales. Como se puede observar, la gráfica muestra una gaussiana cuyo centro de gravedad es aproximadamente 0, por lo tanto, la media se puede despreciar. A continuación, se mostrarán los valores estadísticos más importantes para este estudio, es decir, la media, la desviación típica y el error cuadrático medio (MSE):


- Media: -0.0025
- Desviación típica: 3.7107
- MSE: 13.7691

5.2 Modelo de comportamiento normal de la multiplicadora

Para realizar el modelo de comportamiento de la multiplicadora, el conjunto de entrenamiento se escogerá de los siguientes subcomponentes: el aceite de la multiplicadora y el rodamiento de esta.

-Modelo de comportamiento normal del aceite de la multiplicadora

Para realizar este modelo de comportamiento, la variable de salida será la temperatura del aceite de la multiplicadora y las variables de entrada son las siguientes: temperatura del interior de la nacelle, la potencia total generada y la velocidad del viento. Este es el modelo con sus entradas y salidas:



Primero, se verá una representación del número de capas y el número de neuronas usados:




Figura 18. Modelo de la red neuronal perceptrón multicapa. Arquitectura interna de la red neuronal en el modelo del aceite de la multiplicadora

A continuación, se mostrará la gráfica en la cual se ve el seguimiento del modelo utilizando el conjunto de entrenamiento (los datos que se han usado para crear el modelo). Esta gráfica compara el valor estimado con el valor real.




Figura 19. Modelo de la red neuronal perceptrón multicapa. Comportamiento de la temperatura del aceite de la multiplicadora con datos de entrenamiento. Gráficas comparativas de los valores simulados con los valores reales

Ahora se mostrará el histograma que muestra el error del modelo comparando los valores reales con el simulado.



Figura 20. Modelo de la red neuronal perceptrón multicapa. Comportamiento de la temperatura del aceite de la multiplicadora con datos de entrenamiento. Histograma gaussiano del error del modelo

El histograma muestra los errores de seguimiento del modelo de comportamiento normal utilizando el conjunto de entrenamiento con los valores reales. Como se puede observar, la gráfica muestra una gaussiana cuyo centro de gravedad es aproximadamente 0, por lo tanto, la media se puede despreciar. A continuación, se mostrarán los valores estadísticos más importantes para este estudio, es decir, la media, la desviación típica y el error cuadrático medio (MSE):


-Media: -0.0063

-Desviación típica: 2.5382

-MSE: 6.4424

-Modelo de comportamiento normal del rodamiento de la multiplicadora

Para realizar este modelo de comportamiento, la variable de salida será la temperatura del rodamiento DE del generador y las variables de entrada son las siguientes: temperatura del interior de la nacelle, la potencia total generada y la velocidad del viento. Este es el modelo con sus entradas y salidas:



Primero, se verá una representación del número de capas y el número de neuronas usados:




Figura 21. Modelo de la red neuronal perceptrón multicapa. Arquitectura interna de la red neuronal en el modelo del rodamiento de la multiplicadora

A continuación, se mostrará la gráfica en la cual se ve el seguimiento del modelo utilizando el conjunto de entrenamiento (los datos que se han usado para crear el modelo). Esta gráfica compara el valor estimado con el valor real.




Figura 22. Modelo de la red neuronal perceptrón multicapa. Comportamiento de la temperatura del rodamiento de la multiplicadora con datos de entrenamiento. Gráficas comparativas de los valores simulados con los valores reales

Ahora se mostrará el histograma que muestra el error del modelo comparando los valores reales con el simulado.



Figura 23. Modelo de la red neuronal perceptrón multicapa. Comportamiento de la temperatura del rodamiento de la multiplicadora con datos de entrenamiento. Histograma gaussiano del error del modelo

El histograma muestra los errores de seguimiento del modelo de comportamiento normal utilizando el conjunto de entrenamiento con los valores reales. Como se puede observar, la gráfica muestra una gaussiana cuyo centro de gravedad es aproximadamente 0, por lo tanto, la media se puede despreciar. A continuación, se mostrarán los valores estadísticos más importantes para este estudio, es decir, la media, la desviación típica y el error cuadrático medio (MSE):

-Media: 0.0289

-Desviación típica: 2.7397


-MSE: 5.2867

5.3 Modelo de comportamiento normal del control de paso de pala

Para realizar el modelo de comportamiento del control del paso de pala, el conjunto de entrenamiento se escogerá del siguiente subcomponente: el ángulo de las palas.

-Modelo de comportamiento normal del ángulo de la pala

Para realizar este modelo de comportamiento, la variable de salida será el ángulo de las palas y las variables de entrada son las siguientes: velocidad del viento, la potencia total generada y el ángulo del viento. Este es el modelo con sus entradas y salidas:



Primero, se verá una representación del número de capas y el número de neuronas usados:




Figura 24. Modelo de la red neuronal perceptrón multicapa. Arquitectura interna de la red neuronal en el modelo del paso de las palas

A continuación, se mostrará la gráfica en la cual se ve el seguimiento del modelo utilizando el conjunto de entrenamiento (los datos que se han usado para crear el modelo). Esta gráfica compara el valor estimado con el valor real.




Figura 25. Modelo de la red neuronal perceptrón multicapa. Comportamiento dl ángulo de las palas con datos de entrenamiento. Gráficas comparativas de los valores simulados con los valores reales

Ahora se mostrará el histograma que muestra el error del modelo comparando los valores reales con el simulado.




Figura 26. Modelo de la red neuronal perceptrón multicapa. Comportamiento del ángulo de las palas con datos de entrenamiento. Histograma gaussiano del error del modelo

El histograma muestra los errores de seguimiento del modelo de comportamiento normal utilizando el conjunto de entrenamiento con los valores reales. Como se puede observar, la gráfica muestra una gaussiana cuyo centro de gravedad es aproximadamente 0, por lo tanto, la media se puede despreciar. A continuación, se mostrarán los valores estadísticos más importantes para este estudio, es decir, la media, la desviación típica y el error cuadrático medio (MSE):

-Media: 0.0077

-Desviación típica: 1.0670

-MSE: 1.1385

5.4 Conclusiones

Las conclusiones que podemos sacar de las gráficas se observan sobre todo en los histogramas. Como se ha podido observar, son gráficas gaussianas en las cuales el centro de gravedad se encuentra aproximadamente en 0, por eso la media la Podemos considerar despreciable (también por los resultados obtenidos).

Cabe destacar, que por simple inspección se puede apreciar que el histograma de la temperatura del aceite de la multiplicadora se encuentra un poco más desviado que el resto (posiblemente por la limitación de la temperatura máxima, por lo cual se activa la refrigeración), por lo que el modelo podría funcionar peor que el resto de los modelos. Por otro lado, el histograma del paso de palas tiene una gráfica gaussiana como la esperada, pero por cómo se ve, puede que haya unos pocos valores que se desvíen con errores bastante grandes. Esos valores anómalos se deben tener en cuenta posteriormente para decidir si la anomalía es o no una alarma falsa.

Capítulo 6

Modelo de comportamiento normal basado en una red neuronal RBF

El siguiente método de aprendizaje automatizado será una red neuronal RBF (red neuronal de base radial). Estas redes tienen sus orígenes en los años 80. Al igual que el perceptrón, son redes de tipo multicapa, pero solo tienen una capa oculta y se han aplicado principalmente en análisis de series temporales, reconocimiento automatizado del habla, procesamiento de imágenes... Como se comentó, en el artículo [8] se habla de este tema.

Para la creación de los modelos de este estudio, se utilizó la función newgrnn. Los respectivos códigos se pueden ver en el Anexo V.

Para crear cada uno de los modelos, se utilizará la elección de variables que se mencionó anteriormente. Así, se podrá diferenciar los subcomponentes asignados a cada componente del cual se pretende crear su modelo de comportamiento normal: Modelo del generador (temperatura de los anillos del generador y temperatura de los rodamientos DE y NDE del generador); modelo de la multiplicadora (temperatura del aceite de la multiplicadora y la temperatura del rodamiento de la multiplicadora).

Primero, se comprobará que en todos los modelos habrá un número de capas y el número de neuronas será igual al número de muestras usados:




Figura 27. Modelo de la red neuronal perceptrón multicapa. Arquitectura interna de la red neuronal en el modelo del paso de las palas


A continuación, se explicarán las características de cada modelo de funcionamiento normal utilizado.

6.1 Modelo de comportamiento normal del generador

Para realizar el modelo de comportamiento del generador, el conjunto de entrenamiento se escogerá de los siguientes subcomponentes: los anillos del generador y los rodamientos de este (tanto DE cómo NDE).

-Modelo de comportamiento normal de los anillos del generador

Para realizar este modelo de comportamiento, la variable de salida será la temperatura de los anillos del generador y las variables de entrada son las siguientes: temperatura del interior de la nacelle, la potencia total generada y la velocidad del viento. Este es el modelo con sus entradas y salidas:



A continuación, se mostrará la gráfica en la cual se ve el seguimiento del modelo utilizando el conjunto de entrenamiento (los datos que se han usado para crear el modelo). Esta gráfica compara el valor estimado con el valor real.




Figura 28. Modelo de la red neuronal RBF. Comportamiento de la temperatura de los anillos del generador con datos de entrenamiento. Gráficas comparativas de los valores simulados con los valores reales

Ahora se mostrará el histograma que muestra el error del modelo comparando los valores reales con el simulado.



Figura 29. Modelo de la red neuronal RBF. Comportamiento de la temperatura de los anillos del generador con datos de entrenamiento. Histograma gaussiano del error del modelo

El histograma muestra los errores de seguimiento del modelo de comportamiento normal utilizando el conjunto de entrenamiento con los valores reales. Como se puede observar, la gráfica muestra una gaussiana cuyo centro de gravedad es aproximadamente 0, por lo tanto, la media se puede despreciar. A continuación, se mostrarán los valores estadísticos más importantes para este estudio, es decir, la media, la desviación típica y el error cuadrático medio (MSE):


-Media: $-5.9256 \cdot 10^{-4}$

-Desviación típica: 1.6498

-MSE: 2.7218

-Modelo de comportamiento normal del rodamiento DE del generador

Para realizar este modelo de comportamiento, la variable de salida será la temperatura del rodamiento DE del generador y las variables de entrada son las siguientes: temperatura del interior de la nacelle, la potencia total generada y la velocidad del viento. Este es el modelo con sus entradas y salidas:



A continuación, se mostrará la gráfica en la cual se ve el seguimiento del modelo utilizando el conjunto de entrenamiento (los datos que se han usado para crear el modelo). Esta gráfica compara el valor estimado con el valor real.




Figura 30. Modelo de la red neuronal RBF. Comportamiento de la temperatura del rodamiento DE del generador con datos de entrenamiento. Gráficas comparativas de los valores simulados con los valores reales

Ahora se mostrará el histograma que muestra el error del modelo comparando los valores reales con el simulado.




Figura 31. Modelo de la red neuronal RBF. Comportamiento de la temperatura del rodamiento DE del generador con datos de entrenamiento. Histograma gaussiano del error del modelo

El histograma muestra los errores de seguimiento del modelo de comportamiento normal utilizando el conjunto de entrenamiento con los valores reales. Como se puede observar, la gráfica muestra una gaussiana cuyo centro de gravedad es aproximadamente 0, por lo tanto, la media se puede despreciar. A continuación, se mostrarán los valores estadísticos más importantes para este estudio, es decir, la media, la desviación típica y el error cuadrático medio (MSE):

- Media: -0.0030
- Desviación típica: 2.2922
- MSE: 5.2540

-Modelo de comportamiento normal del rodamiento NDE del generador

Para realizar este modelo de comportamiento, la variable de salida será la temperatura del rodamiento NDE del generador y las variables de entrada son las siguientes: temperatura del interior de la nacelle, la potencia total generada y la velocidad del viento. Este es el modelo con sus entradas y salidas:



A continuación, se mostrará la gráfica en la cual se ve el seguimiento del modelo utilizando el conjunto de entrenamiento (los datos que se han usado para crear el modelo). Esta gráfica compara el valor estimado con el valor real.




Figura 32. Modelo de la red neuronal RBF. Comportamiento de la temperatura del rodamiento NDE del generador con datos de entrenamiento. Gráficas comparativas de los valores simulados con los valores reales

Ahora se mostrará el histograma que muestra el error del modelo comparando los valores reales con el simulado.




Figura 33. Modelo de la red neuronal RBF. Comportamiento de la temperatura del rodamiento NDE del generador con datos de entrenamiento. Histograma gaussiano del error del modelo

El histograma muestra los errores de seguimiento del modelo de comportamiento normal utilizando el conjunto de entrenamiento con los valores reales. Como se puede observar, la gráfica muestra una gaussiana cuyo centro de gravedad es aproximadamente 0, por lo tanto, la media se puede despreciar. A continuación, se mostrarán los valores estadísticos más importantes para este estudio, es decir, la media, la desviación típica y el error cuadrático medio (MSE):


- Media: 0.0014
- Desviación típica: 3.1550
- MSE: 9.9535

6.2 Modelo de comportamiento normal de la multiplicadora

Para realizar el modelo de comportamiento de la multiplicadora, el conjunto de entrenamiento se escogerá de los siguientes subcomponentes: el aceite de la multiplicadora y el rodamiento de esta.

-Modelo de comportamiento normal del aceite de la multiplicadora

Para realizar este modelo de comportamiento, la variable de salida será la temperatura del aceite de la multiplicadora y las variables de entrada son las siguientes: temperatura del interior de la nacelle, la potencia total generada y la velocidad del viento. Este es el modelo con sus entradas y salidas:



A continuación, se mostrará la gráfica en la cual se ve el seguimiento del modelo utilizando el conjunto de entrenamiento (los datos que se han usado para crear el modelo). Esta gráfica compara el valor estimado con el valor real.




Figura 34. Modelo de la red neuronal RBF. Comportamiento de la temperatura del aceite de la multiplicadora con datos de entrenamiento. Gráficas comparativas de los valores simulados con los valores reales

Ahora se mostrará el histograma que muestra el error del modelo comparando los valores reales con el simulado.




Figura 35. Modelo de la red neuronal RBF. Comportamiento de la temperatura del aceite de la multiplicadora con datos de entrenamiento. Histograma gaussiano del error del modelo

El histograma muestra los errores de seguimiento del modelo de comportamiento normal utilizando el conjunto de entrenamiento con los valores reales. Como se puede observar, la gráfica muestra una gaussiana cuyo centro de gravedad es aproximadamente 0, por lo tanto, la media se puede despreciar. A continuación, se mostrarán los valores estadísticos más importantes para este estudio, es decir, la media, la desviación típica y el error cuadrático medio (MSE):


-Media: 0.0042

-Desviación típica: 2.1647

-MSE: 4.6857

-Modelo de comportamiento normal del rodamiento de la multiplicadora

Para realizar este modelo de comportamiento, la variable de salida será la temperatura del rodamiento DE del generador y las variables de entrada son las siguientes: temperatura del interior de la nacelle, la potencia total generada y la velocidad del viento. Este es el modelo con sus entradas y salidas:



A continuación, se mostrará la gráfica en la cual se ve el seguimiento del modelo utilizando el conjunto de entrenamiento (los datos que se han usado para crear el modelo). Esta gráfica compara el valor estimado con el valor real.




Figura 36. Modelo de la red neuronal RBF. Comportamiento de la temperatura del rodamiento de la multiplicadora con datos de entrenamiento. Gráficas comparativas de los valores simulados con los valores reales

Ahora se mostrará el histograma que muestra el error del modelo comparando los valores reales con el simulado.




Figura 37. Modelo de la red neuronal RBF. Comportamiento de la temperatura del rodamiento de la multiplicadora con datos de entrenamiento. Histograma gaussiano del error del modelo

El histograma muestra los errores de seguimiento del modelo de comportamiento normal utilizando el conjunto de entrenamiento con los valores reales. Como se puede observar, la gráfica muestra una gaussiana cuyo centro de gravedad es aproximadamente 0, por lo tanto, la media se puede despreciar. A continuación, se mostrarán los valores estadísticos más importantes para este estudio, es decir, la media, la desviación típica y el error cuadrático medio (MSE):


- Media: 0.0026
- Desviación típica: 1.9701
- MSE: 3.8812

6.3 Modelo de comportamiento normal del control de paso de pala

Para realizar el modelo de comportamiento del control del paso de pala, el conjunto de entrenamiento se escogerá del siguiente subcomponente: el ángulo de las palas.

-Modelo de comportamiento normal del ángulo de la pala

Para realizar este modelo de comportamiento, la variable de salida será el ángulo de las palas y las variables de entrada son las siguientes: velocidad del viento, la potencia total generada y el ángulo del viento. Este es el modelo con sus entradas y salidas:



A continuación, se mostrará la gráfica en la cual se ve el seguimiento del modelo utilizando el conjunto de entrenamiento (los datos que se han usado para crear el modelo). Esta gráfica compara el valor estimado con el valor real.




Figura 38. Modelo de la red neuronal RBF. Comportamiento dl ángulo de las palas con datos de entrenamiento. Gráficas comparativas de los valores simulados con los valores reales

Ahora se mostrará el histograma que muestra el error del modelo comparando los valores reales con el simulado.




Figura 39. Modelo de la red neuronal RBF. Comportamiento del ángulo de las palas con datos de entrenamiento. Histograma gaussiano del error del modelo

El histograma muestra los errores de seguimiento del modelo de comportamiento normal utilizando el conjunto de entrenamiento con los valores reales. Como se puede observar, la gráfica muestra una gaussiana cuyo centro de gravedad es aproximadamente 0, por lo tanto, la media se puede despreciar. A continuación, se mostrarán los valores estadísticos más importantes para este estudio, es decir, la media, la desviación típica y el error cuadrático medio (MSE):

-Media: 0.0077

-Desviación típica: 0.8637

-MSE: 0.7461

6.4 Conclusiones

Las conclusiones que podemos sacar de las gráficas se observan sobre todo en los histogramas. Como se ha podido observar, son gráficas gaussianas en las cuales el centro de gravedad se encuentra aproximadamente en 0, por eso la media la Podemos considerar despreciable (también por los resultados obtenidos).

Cabe destacar, que por simple inspección se puede apreciar que el histograma de la temperatura del aceite de la multiplicadora se encuentra un poco más desviado que el resto, por lo que el modelo podría funcionar peor que el resto de los modelos. Por otro lado, el histograma del paso de palas tiene una gráfica gaussiana como la esperada, pero por cómo se ve, puede que haya unos pocos valores que se desvíen con errores bastante grandes. Esos valores anómalos se deben tener en cuenta posteriormente para decidir si la anomalía es o no una alarma falsa.

Capítulo 7

Modelo de comportamiento normal basado en la máquina de soporte vectorial (SVM)

A continuación, la herramienta que se verá es la máquina de soporte vectorial (SVM). Estos algoritmos, desarrollados por Vladimir Vapnik, permite clasificar distintos valores o datos y situarlas en distintas categorías. Como se comentó, en el artículo [9] se habla de este tema.

Para la creación de los modelos de este estudio, se utilizó la función `fitrsvm`. Los respectivos códigos se pueden ver en el Anexo VI.

El criterio usado para distinguir una alarma real y una falsa alarma será que si se detecta 3 o más anomalías seguidas la alarma será real.

Para crear cada uno de los modelos, se utilizará la elección de variables que se mencionó anteriormente. Así, se podrá diferenciar los subcomponentes asignadas a cada componente del cual se pretende crear su modelo de comportamiento normal: Modelo del generador (temperatura de los anillos del generador y temperatura de los rodamientos DE y NDE del generador); modelo de la multiplicadora (temperatura del aceite de la multiplicadora y la temperatura del rodamiento de la multiplicadora).


A continuación, se explicarán las características de cada modelo de funcionamiento normal utilizado.

7.1 Modelo de comportamiento normal del generador

Para realizar el modelo de comportamiento del generador, el conjunto de entrenamiento se escogerá de los siguientes subcomponentes: los anillos del generador y los rodamientos de este (tanto DE cómo NDE).

-Modelo de comportamiento normal de los anillos del generador

Para realizar este modelo de comportamiento, la variable de salida será la temperatura de los anillos del generador y las variables de entrada son las siguientes: temperatura del interior de la nacelle, la potencia total generada y la velocidad del viento. Este es el modelo con sus entradas y salidas:



A continuación, se mostrará la gráfica en la cual se ve el seguimiento del modelo utilizando el conjunto de entrenamiento (los datos que se han usado para crear el modelo). Esta gráfica compara el valor estimado con el valor real.




Figura 40. Modelo SVM. Comportamiento de la temperatura de los anillos del generador con datos de entrenamiento. Gráficas comparativas de los valores simulados con los valores reales

Ahora se mostrará el histograma que muestra el error del modelo comparando los valores reales con el simulado.




Figura 41. Modelo de la red neuronal RBF. Comportamiento de la temperatura de los anillos del generador con datos de entrenamiento. Histograma gaussiano del error del modelo

El histograma muestra los errores de seguimiento del modelo de comportamiento normal utilizando el conjunto de entrenamiento con los valores reales. Como se puede observar, la gráfica muestra una gaussiana cuyo centro de gravedad es aproximadamente 0, por lo tanto, la media se puede despreciar. A continuación, se mostrarán los valores estadísticos más importantes para este estudio, es decir, la media, la desviación típica y el error cuadrático medio (MSE):

- Media: 0.1451
- Desviación típica: 1.9844
- MSE: 3.9746

-Modelo de comportamiento normal del rodamiento DE del generador

Para realizar este modelo de comportamiento, la variable de salida será la temperatura del rodamiento DE del generador y las variables de entrada son las siguientes: temperatura del interior de la nacelle, la potencia total generada y la velocidad del viento. Este es el modelo con sus entradas y salidas:



A continuación, se mostrará la gráfica en la cual se ve el seguimiento del modelo utilizando el conjunto de entrenamiento (los datos que se han usado para crear el modelo). Esta gráfica compara el valor estimado con el valor real.




Figura 42. Modelo SVM. Comportamiento de la temperatura del rodamiento DE del generador con datos de entrenamiento. Gráficas comparativas de los valores simulados con los valores reales

Ahora se mostrará el histograma que muestra el error del modelo comparando los valores reales con el simulado.





Figura 43. Modelo SVM. Comportamiento de la temperatura del rodamiento DE del generador con datos de entrenamiento. Histograma gaussiano del error del modelo

El histograma muestra los errores de seguimiento del modelo de comportamiento normal utilizando el conjunto de entrenamiento con los valores reales. Como se puede observar, la gráfica muestra una gaussiana cuyo centro de gravedad es aproximadamente 0, por lo tanto, la media se puede despreciar. A continuación, se mostrarán los valores estadísticos más importantes para este estudio, es decir, la media, la desviación típica y el error cuadrático medio (MSE):

- Media: -0.0664
- Desviación típica: 2.8122
- MSE: 7.9127

-Modelo de comportamiento normal del rodamiento NDE del generador

Para realizar este modelo de comportamiento, la variable de salida será la temperatura del rodamiento NDE del generador y las variables de entrada son las siguientes: temperatura del interior de la nacelle, la potencia total generada y la velocidad del viento. Este es el modelo con sus entradas y salidas:



A continuación, se mostrará la gráfica en la cual se ve el seguimiento del modelo utilizando el conjunto de entrenamiento (los datos que se han usado para crear el modelo). Esta gráfica compara el valor estimado con el valor real.




Figura 44. Modelo SVM. Comportamiento de la temperatura del rodamiento NDE del generador con datos de entrenamiento. Gráficas comparativas de los valores simulados con los valores reales

Ahora se mostrará el histograma que muestra el error del modelo comparando los valores reales con el simulado.




Figura 45. Modelo SVM. Comportamiento de la temperatura del rodamiento NDE del generador con datos de entrenamiento. Histograma gaussiano del error del modelo

El histograma muestra los errores de seguimiento del modelo de comportamiento normal utilizando el conjunto de entrenamiento con los valores reales. Como se puede observar, la gráfica muestra una gaussiana cuyo centro de gravedad es aproximadamente 0, por lo tanto, la media se puede despreciar. A continuación, se mostrarán los valores estadísticos más importantes para este estudio, es decir, la media, la desviación típica y el error cuadrático medio (MSE):

-Media: -0.3914

-Desviación típica: 3.7911


-MSE: 14.4742

7.2 Modelo de comportamiento normal de la multiplicadora

Para realizar el modelo de comportamiento de la multiplicadora, el conjunto de entrenamiento se escogerá de los siguientes subcomponentes: el aceite de la multiplicadora y el rodamiento de esta.

-Modelo de comportamiento normal del aceite de la multiplicadora

Para realizar este modelo de comportamiento, la variable de salida será la temperatura del aceite de la multiplicadora y las variables de entrada son las siguientes: temperatura del interior de la nacelle, la potencia total generada y la velocidad del viento. Este es el modelo con sus entradas y salidas:



A continuación, se mostrará la gráfica en la cual se ve el seguimiento del modelo utilizando el conjunto de entrenamiento (los datos que se han usado para crear el modelo). Esta gráfica compara el valor estimado con el valor real.




Figura 46. Modelo SVM. Comportamiento de la temperatura del aceite de la multiplicadora con datos de entrenamiento. Gráficas comparativas de los valores simulados con los valores reales

Ahora se mostrará el histograma que muestra el error del modelo comparando los valores reales con el simulado.




Figura 47. Modelo SVM. Comportamiento de la temperatura del aceite de la multiplicadora con datos de entrenamiento. Histograma gaussiano del error del modelo

El histograma muestra los errores de seguimiento del modelo de comportamiento normal utilizando el conjunto de entrenamiento con los valores reales. Como se puede observar, la gráfica muestra una gaussiana cuyo centro de gravedad es aproximadamente 0, por lo tanto, la media se puede despreciar. A continuación, se mostrarán los valores estadísticos más importantes para este estudio, es decir, la media, la desviación típica y el error cuadrático medio (MSE):

- Media: -0.04987
- Desviación típica: 2.6158
- MSE: 7.0912

-Modelo de comportamiento normal del rodamiento de la multiplicadora

Para realizar este modelo de comportamiento, la variable de salida será la temperatura del rodamiento DE del generador y las variables de entrada son las siguientes: temperatura del interior de la nacelle, la potencia total generada y la velocidad del viento. Este es el modelo con sus entradas y salidas:



A continuación, se mostrará la gráfica en la cual se ve el seguimiento del modelo utilizando el conjunto de entrenamiento (los datos que se han usado para crear el modelo). Esta gráfica compara el valor estimado con el valor real.




Figura 48. Modelo SVM. Comportamiento de la temperatura del rodamiento de la multiplicadora con datos de entrenamiento. Gráficas comparativas de los valores simulados con los valores reales

Ahora se mostrará el histograma que muestra el error del modelo comparando los valores reales con el simulado.



Figura 49. Modelo SVM. Comportamiento de la temperatura del rodamiento de la multiplicadora con datos de entrenamiento. Histograma gaussiano del error del modelo

El histograma muestra los errores de seguimiento del modelo de comportamiento normal utilizando el conjunto de entrenamiento con los valores reales. Como se puede observar, la gráfica muestra una gaussiana cuyo centro de gravedad es aproximadamente 0, por lo tanto, la media se puede desprestigiar. A continuación, se mostrarán los valores estadísticos más importantes para este estudio, es decir, la media, la desviación típica y el error cuadrático medio (MSE):


- Media: -0.1178
- Desviación típica: 2.3833
- MSE: 5.6940

7.3 Modelo de comportamiento normal del control de paso de pala

Para realizar el modelo de comportamiento del control del paso de pala, el conjunto de entrenamiento se escogerá del siguiente subcomponente: el ángulo de las palas.

-Modelo de comportamiento normal del ángulo de la pala

Para realizar este modelo de comportamiento, la variable de salida será el ángulo de las palas y las variables de entrada son las siguientes: velocidad del viento, la potencia total generada y el ángulo del viento. Este es el modelo con sus entradas y salidas:



A continuación, se mostrará la gráfica en la cual se ve el seguimiento del modelo utilizando el conjunto de entrenamiento (los datos que se han usado para crear el modelo). Esta gráfica compara el valor estimado con el valor real.




Figura 50. Modelo SVM. Comportamiento dl ángulo de las palas con datos de entrenamiento.
Gráficas comparativas de los valores simulados con los valores reales

Ahora se mostrará el histograma que muestra el error del modelo comparando los valores reales con el simulado.




Figura 51. Modelo SVM. Comportamiento del ángulo de las palas con datos de entrenamiento.
Histograma gaussiano del error del modelo

El histograma muestra los errores de seguimiento del modelo de comportamiento normal utilizando el conjunto de entrenamiento con los valores reales. Como se puede observar, la gráfica muestra una gaussiana cuyo centro de gravedad es aproximadamente 0, por lo tanto, la media se puede despreciar. A continuación, se mostrarán los valores estadísticos más importantes para este estudio, es decir, la media, la desviación típica y el error cuadrático medio (MSE):

-Media: 0.1217

-Desviación típica: 1.2390

-MSE: 1.5498

7.4 Conclusiones

Las conclusiones que podemos sacar de las gráficas se observan sobre todo en los histogramas. Como se ha podido observar, son gráficas gaussianas en las cuales el centro de gravedad se encuentra aproximadamente en 0, por eso la media la Podemos considerar despreciable (también por los resultados obtenidos).

Cabe destacar, que por simple inspección se puede apreciar que el histograma de la temperatura del aceite de la multiplicadora se encuentra un poco más desviado que el resto, por lo que el modelo podría funcionar peor que el resto de los modelos. Por otro lado, el histograma del paso de palas tiene una gráfica gaussiana como la esperada, pero por cómo se ve, puede que haya unos pocos valores que se desvíen con errores bastante grandes. Esos valores anómalos se deben tener en cuenta posteriormente para decidir si la anomalía es o no una alarma falsa.

La forma de los histogramas es muy parecida al del perceptrón multicapa y la red neuronal RBF.

Capítulo 8

Comparación de modelos de funcionamiento normal

Una vez se haya creado los modelos de funcionamiento utilizando los datos de entrenamiento, se procederá a dar una visión general de todos ellos. Se hará una comparación de todos los modelos en cada variable que se usó para el entrenamiento.

A continuación, se verá una tabla con cada uno de los modelos para poder comparas todas las herramientas de aprendizaje automatizado que se han usado. En dicha tabla, se comparará los valores estadísticos de cada uno de los errores: media, desviación típica y error cuadrático medio (MSE).

El código de colores que se utilizará será azul para que la red neuronal perceptrón multicapa, verde para la red neuronal RBF y rojo para el SVM.

Modelo	Media			Desviación típica			MSE		
	Perceptrón	RBF	SVM	Perceptrón	RBF	SVM	Perceptrón	RBF	SVM
Anillos del generador	$5.4 \cdot 10^{-4}$	$-5.9 \cdot 10^{-4}$	0.1451	1.9351	1.6498	1.9844	3.7746	2.7218	3.9746
Rodamiento DE del generador	0.0770	-0.0030	-0.0664	2.7397	2.2922	2.8122	7.5119	5.2540	7.9127
Rodamiento NDE del generador	-0.0025	0.0014	-0.3914	3.7107	3.1550	3.7911	13.7691	9.9535	14.4742
Aceite de la multiplicadora	-0.0063	0.0042	-0.04987	2.5382	2.1647	2.6158	6.4424	4.6857	7.0912
Rodamiento de la multiplicadora	0.0289	0.0026	-0.1178	2.7397	1.9701	2.3833	5.2867	3.8812	5.6940
Paso de las palas	0.0077	0.0077	0.1217	1.0670	0.8637	1.2390	1.1385	0.7461	1.5498

Tabla 1. Comparación estadística de los modelos de comportamiento

8.1 Conclusiones

Lo que se puede observar de los valores estadísticos de los errores en cada modelo es que la red neuronal RBF tiene la menor desviación típica en cada modelo mientras que los modelos basados en SVM tienen la mayor desviación típica menos en el modelo del rodamiento de la multiplicadora. Los modelos de mayor desviación típica son aquellos que tienen mayor grado de dispersión respecto al valor promedio, es decir, sus valores tienden a estar más alejados de la media.


Respecto a la media, como todos los valores son aproximadamente 0, se pueden despreciar a la hora de realizar cálculos. Eso se puede ver en las gráficas, ya que son gaussianas cuyo centro de gravedad se encuentra en 0.

Por último, la red neuronal RBF tiene el menor error cuadrático medio (MSE) en todos los modelos, mientras que el SVM tiene mayor MSE en todos los modelos. Mientras mayor sea el MSE, menor será el seguimiento entre la monitorización de las variables y el valor real que se pretende seguir.

Capítulo 9

Detección de anomalías

Una vez obtenido los modelos de comportamiento normal, se procede a realizar la detección de anomalías de los años posteriores al año del que pertenece el conjunto de entrenamiento (años 2011, 2012, 2013 y 2014). Para eso, se utilizan los modelos obtenidos y utilizaremos los datos de monitorización como variables de entrada, y la salida corresponderá a la simulación de esos datos de monitorización. Esa simulación se creará de la siguiente manera:



A continuación, se comparará los datos de la simulación con los datos reales. De esa forma, se estudiará el error existente en ambos datos. Con la desviación típica calculada previamente se crearán unas bandas de confianza ($2 \cdot \text{desviación típica}$) de tal forma que si el error es mayor que ese valor, se considerará que en ese punto hay una anomalía.

Para finalizar, los modelos utilizados anteriormente se colocarán en paralelo. Eso permitirá tener mayor robustez a la hora de detectar anomalías de los componentes del aerogenerador. Eso logrará que la simulación de los datos de entrada tenga un mejor seguimiento respecto a la realidad y el modelo no se verá afectado ante pequeñas variaciones.

Una vez detectadas las anomalías en cada componente utilizando ese criterio, se procede a diferenciar las alarmas reales de las falsas. El criterio usado para distinguir una alarma real y una falsa alarma será que si se detecta 3 o más anomalías seguidas la alarma será real.

A continuación, se representarán las anomalías detectadas en cada componente, mostrando únicamente las alarmas reales (las anomalías se muestran teniendo valor 1 en los puntos donde se presentan las anomalías). Las gráficas representan cada anomalía en cada una de las muestras de monitorización. Posteriormente se definirá el índice en el

cual se calcula las anomalías por unidad de tiempo:

Se verán las gráficas de los histogramas de errores, en el anexo VII y los códigos utilizados en el anexo VIII.

9.1 Utilizando el modelo de comportamiento normal de la red neuronal perceptrón multicapa

9.1.1 Año 2011

-Modelo de comportamiento normal del generador:

-Modelo de comportamiento normal de los anillos del generador:




Figura 52. Modelo de la red neuronal perceptrón multicapa. Detección de anomalías en los anillos del generador. Alarmas reales. Año 2011

-Modelo de comportamiento normal del rodamiento DE del generador:




Figura 53. Modelo de la red neuronal perceptrón multicapa. Detección de anomalías en el rodamiento DE del generador. Alarmas reales. Año 2011

-Modelo de comportamiento normal del rodamiento NDE del generador:




Figura 54. Modelo de la red neuronal perceptrón multicapa. Detección de anomalías en el rodamiento NDE del generador. Alarmas reales. Año 2011

-Modelo de comportamiento normal de la multiplicadora:

-Modelo de comportamiento normal de la temperatura del aceite de la multiplicadora:




Figura 55. Modelo de la red neuronal perceptrón multicapa. Detección de anomalías en el aceite de la multiplicadora. Alarmas reales. Año 2011

-Modelo de comportamiento normal del rodamiento de la multiplicadora:




Figura 56. Modelo de la red neuronal perceptrón multicapa. Detección de anomalías en el rodamiento de la multiplicadora. Alarmas reales. Año 2011

-Modelo de comportamiento normal del control del paso de pala:

-Modelo de comportamiento normal del ángulo de las palas:




Figura 57. Modelo de la red neuronal perceptrón multicapa. Detección de anomalías en el ángulo de las palas. Alarmas reales. Año 2011

9.1.2 Año 2012

-Modelo de comportamiento normal del generador:

-Modelo de comportamiento normal de los anillos del generador:




Figura 58. Modelo de la red neuronal perceptrón multicapa. Detección de anomalías en los anillos del generador. Alarmas reales. Año 2012

-Modelo de comportamiento normal del rodamiento DE del generador:




Figura 59. Modelo de la red neuronal perceptrón multicapa. Detección de anomalías en el rodamiento DE del generador. Alarmas reales. Año 2012

-Modelo de comportamiento normal del rodamiento NDE del generador:




Figura 60. Modelo de la red neuronal perceptrón multicapa. Detección de anomalías en el rodamiento NDE del generador. Alarmas reales. Año 2012

-Modelo de comportamiento normal de la multiplicadora:

-Modelo de comportamiento normal de la temperatura del aceite de la multiplicadora:




Figura 61. Modelo de la red neuronal perceptrón multicapa. Detección de anomalías en el aceite de la multiplicadora. Alarmas reales. Año 2012

-Modelo de comportamiento normal del rodamiento de la multiplicadora:




Figura 62. Modelo de la red neuronal perceptrón multicapa. Detección de anomalías en el rodamiento de la multiplicadora. Alarmas reales. Año 2012

-Modelo de comportamiento normal del control del paso de pala:

-Modelo de comportamiento normal del ángulo de las palas:




Figura 63. Modelo de la red neuronal perceptrón multicapa. Detección de anomalías en el ángulo de las palas. Alarmas reales. Año 2012

9.1.3 Año 2013

-Modelo de comportamiento normal del generador:

-Modelo de comportamiento normal de los anillos del generador:




Figura 64. Modelo de la red neuronal perceptrón multicapa. Detección de anomalías en los anillos del generador. Alarmas reales. Año 2013

-Modelo de comportamiento normal del rodamiento DE del generador:




Figura 65. Modelo de la red neuronal perceptrón multicapa. Detección de anomalías en el rodamiento DE del generador. Alarmas reales. Año 2013

-Modelo de comportamiento normal del rodamiento NDE del generador:




Figura 66. Modelo de la red neuronal perceptrón multicapa. Detección de anomalías en el rodamiento NDE del generador. Alarmas reales. Año 2013

-Modelo de comportamiento normal de la multiplicadora:

-Modelo de comportamiento normal de la temperatura del aceite de la multiplicadora:




Figura 67. Modelo de la red neuronal perceptrón multicapa. Detección de anomalías en el aceite de la multiplicadora. Alarmas reales. Año 2013

-Modelo de comportamiento normal del rodamiento de la multiplicadora:




Figura 68. Modelo de la red neuronal perceptrón multicapa. Detección de anomalías en el rodamiento de la multiplicadora. Alarmas reales. Año 2013

-Modelo de comportamiento normal del control del paso de pala:

-Modelo de comportamiento normal del ángulo de las palas:




Figura 69. Modelo de la red neuronal perceptrón multicapa. Detección de anomalías en el ángulo de las palas. Alarmas reales. Año 2013

9.1.4 Año 2014

-Modelo de comportamiento normal del generador:

-Modelo de comportamiento normal de los anillos del generador:




Figura 70. Modelo de la red neuronal perceptrón multicapa. Detección de anomalías en los anillos del generador. Alarmas reales. Año 2014

-Modelo de comportamiento normal del rodamiento DE del generador:




Figura 71. Modelo de la red neuronal perceptrón multicapa. Detección de anomalías en el rodamiento DE del generador. Alarmas reales. Año 2014

-Modelo de comportamiento normal del rodamiento NDE del generador:




Figura 72. Modelo de la red neuronal perceptrón multicapa. Detección de anomalías en el rodamiento NDE del generador. Alarmas reales. Año 2014

-Modelo de comportamiento normal de la multiplicadora:

-Modelo de comportamiento normal de la temperatura del aceite de la multiplicadora:




Figura 73. Modelo de la red neuronal perceptrón multicapa. Detección de anomalías en el aceite de la multiplicadora. Alarmas reales. Año 2014

-Modelo de comportamiento normal del rodamiento de la multiplicadora:




Figura 74. Modelo de la red neuronal perceptrón multicapa. Detección de anomalías en el rodamiento de la multiplicadora. Alarmas reales. Año 2014

-Modelo de comportamiento normal del control del paso de pala:

-Modelo de comportamiento normal del ángulo de las palas:




Figura 75. Modelo de la red neuronal perceptrón multicapa. Detección de anomalías en el ángulo de las palas. Alarmas reales. Año 2014

9.2 Utilizando el modelo de comportamiento normal de la red neuronal RBF

9.2.1 Año 2011

-Modelo de comportamiento normal del generador:

-Modelo de comportamiento normal de los anillos del generador:




Figura 76. Modelo de la red neuronal RBF. Detección de anomalías en los anillos del generador. Alarmas reales. Año 2011

-Modelo de comportamiento normal del rodamiento DE del generador:




Figura 77. Modelo de la red neuronal RBF. Detección de anomalías en el rodamiento DE del generador. Alarmas reales. Año 2011

-Modelo de comportamiento normal del rodamiento NDE del generador:




Figura 78. Modelo de la red neuronal RBF. Detección de anomalías en el rodamiento NDE del generador. Alarmas reales. Año 2011

-Modelo de comportamiento normal de la multiplicadora:

-Modelo de comportamiento normal de la temperatura del aceite de la multiplicadora:




Figura 79. Modelo de la red neuronal perceptrón multicapa. Detección de anomalías en el aceite de la multiplicadora. Alarmas reales. Año 2011

-Modelo de comportamiento normal del rodamiento de la multiplicadora:




Figura 80. Modelo de la red neuronal RBF. Detección de anomalías en el rodamiento de la multiplicadora. Alarmas reales. Año 2011

-Modelo de comportamiento normal del control del paso de pala:

-Modelo de comportamiento normal del ángulo de las palas:




Figura 81. Modelo de la red neuronal RBF. Detección de anomalías en el ángulo de las palas. Alarmas reales. Año 2011

9.2.2 Año 2012

-Modelo de comportamiento normal del generador:

-Modelo de comportamiento normal de los anillos del generador:




Figura 82. Modelo de la red neuronal RBF. Detección de anomalías en los anillos del generador. Alarmas reales. Año 2012

-Modelo de comportamiento normal del rodamiento DE del generador:




Figura 83. Modelo de la red neuronal RBF. Detección de anomalías en el rodamiento DE del generador. Alarmas reales. Año 2012

-Modelo de comportamiento normal del rodamiento NDE del generador:




Figura 84. Modelo de la red neuronal RBF. Detección de anomalías en el rodamiento NDE del generador. Alarmas reales. Año 2012

-Modelo de comportamiento normal de la multiplicadora:

-Modelo de comportamiento normal de la temperatura del aceite de la multiplicadora:




Figura 85. Modelo de la red neuronal RBF. Detección de anomalías en el aceite de la multiplicadora. Alarmas reales. Año 2012

-Modelo de comportamiento normal del rodamiento de la multiplicadora:




Figura 86. Modelo de la red neuronal RBF. Detección de anomalías en el rodamiento de la multiplicadora. Alarmas reales. Año 2012

-Modelo de comportamiento normal del control del paso de pala:

-Modelo de comportamiento normal de la temperatura del aceite de la multiplicadora:




Figura 87. Modelo de la red neuronal RBF. Detección de anomalías en el ángulo de las palas. Alarmas reales. Año 2012

9.2.3 Año 2013

-Modelo de comportamiento normal del generador:

-Modelo de comportamiento normal de los anillos del generador:




Figura 88. Modelo de la red neuronal RBF. Detección de anomalías en los anillos del generador. Alarmas reales. Año 2013

-Modelo de comportamiento normal del rodamiento DE del generador:




Figura 89. Modelo de la red neuronal RBF. Detección de anomalías en el rodamiento DE del generador. Alarmas reales. Año 2013

-Modelo de comportamiento normal del rodamiento NDE del generador:




Figura 90. Modelo de la red neuronal RBF. Detección de anomalías en el rodamiento NDE del generador. Alarmas reales. Año 2013

-Modelo de comportamiento normal de la multiplicadora:

-Modelo de comportamiento normal de la temperatura del aceite de la multiplicadora:




Figura 91. Modelo de la red neuronal RBF. Detección de anomalías en el aceite de la multiplicadora. Alarmas reales. Año 2013

-Modelo de comportamiento normal del rodamiento de la multiplicadora:




Figura 92. Modelo de la red neuronal RBF. Detección de anomalías en el rodamiento de la multiplicadora. Alarmas reales. Año 2013

-Modelo de comportamiento normal del control del paso de pala:

-Modelo de comportamiento normal de la temperatura del aceite de la multiplicadora:




Figura 93. Modelo de la red neuronal RBF. Detección de anomalías en el ángulo de las palas. Alarmas reales. Año 2013

9.2.4 Año 2014

-Modelo de comportamiento normal del generador:

-Modelo de comportamiento normal de los anillos del generador:




Figura 94. Modelo de la red neuronal RBF. Detección de anomalías en los anillos del generador. Alarmas reales. Año 2014

-Modelo de comportamiento normal del rodamiento DE del generador:




Figura 95. Modelo de la red neuronal RBF. Detección de anomalías en el rodamiento DE del generador. Alarmas reales. Año 2014

-Modelo de comportamiento normal del rodamiento NDE del generador:




Figura 96. Modelo de la red neuronal RBF. Detección de anomalías en el rodamiento NDE del generador. Alarmas reales. Año 2014

-Modelo de comportamiento normal de la multiplicadora:

-Modelo de comportamiento normal de la temperatura del aceite de la multiplicadora:




Figura 97. Modelo de la red neuronal RBF. Detección de anomalías en el aceite de la multiplicadora. Alarmas reales. Año 2014

-Modelo de comportamiento normal del rodamiento de la multiplicadora:




Figura 98. Modelo de la red neuronal RBF. Detección de anomalías en el rodamiento de la multiplicadora. Alarmas reales. Año 2014

-Modelo de comportamiento normal del control del paso de pala:

-Modelo de comportamiento normal de la temperatura del aceite de la multiplicadora:




Figura 99. Modelo de la red neuronal RBF. Detección de anomalías en el ángulo de las palas. Alarmas reales. Año 2014

9.3 Utilizando el modelo de comportamiento normal de la máquina de soporte vectorial (SVM)

9.3.1 Año 2011

-Modelo de comportamiento normal del generador:

-Modelo de comportamiento normal de los anillos del generador:




Figura 100. Modelo de SVM. Detección de anomalías en los anillos del generador. Alarmas reales. Año 2011

-Modelo de comportamiento normal del rodamiento DE del generador:




Figura 101. Modelo de SVM. Detección de anomalías en el rodamiento DE del generador. Alarmas reales. Año 2011

-Modelo de comportamiento normal del rodamiento NDE del generador:




Figura 102. Modelo de SVM. Detección de anomalías en el rodamiento NDE del generador. Alarmas reales. Año 2011

-Modelo de comportamiento normal de la multiplicadora:

-Modelo de comportamiento normal de la temperatura del aceite de la multiplicadora:




Figura 103. Modelo de SVM. Detección de anomalías en el aceite de la multiplicadora. Alarmas reales. Año 2011

-Modelo de comportamiento normal del rodamiento de la multiplicadora:




Figura 104. Modelo de SVM. Detección de anomalías en el rodamiento de la multiplicadora. Alarmas reales. Año 2011

-Modelo de comportamiento normal del control del paso de pala:

-Modelo de comportamiento normal del ángulo de las palas:




Figura 105. Modelo de SVM. Detección de anomalías en el ángulo de las palas. Alarmas reales. Año 2011

9.3.2 Año 2012

-Modelo de comportamiento normal del generador:

-Modelo de comportamiento normal de los anillos del generador:




Figura 106. Modelo de SVM. Detección de anomalías en los anillos del generador. Alarmas reales. Año 2012

-Modelo de comportamiento normal del rodamiento DE del generador:




Figura 107. Modelo de SVM. Detección de anomalías en el rodamiento DE del generador. Alarmas reales. Año 2012

-Modelo de comportamiento normal del rodamiento NDE del generador:




Figura 108. Modelo de SVM. Detección de anomalías en el rodamiento NDE del generador. Alarmas reales. Año 2012

-Modelo de comportamiento normal de la multiplicadora:

-Modelo de comportamiento normal de la temperatura del aceite de la multiplicadora:




Figura 109. Modelo de SVM. Detección de anomalías en el aceite de la multiplicadora. Alarmas reales. Año 2012

-Modelo de comportamiento normal del rodamiento de la multiplicadora:




Figura 110. Modelo de SVM. Detección de anomalías en el rodamiento de la multiplicadora. Alarmas reales. Año 2012

-Modelo de comportamiento normal del control del paso de pala:

-Modelo de comportamiento normal de la temperatura del aceite de la multiplicadora:




Figura 1101. Modelo SVM. Detección de anomalías en el ángulo de las palas. Alarmas reales. Año 2012

9.3.3 Año 2013

-Modelo de comportamiento normal del generador:

-Modelo de comportamiento normal de los anillos del generador:




Figura 112. Modelo de SVM. Detección de anomalías en los anillos del generador. Alarmas reales. Año 2013

-Modelo de comportamiento normal del rodamiento DE del generador:




Figura 113. Modelo de SVM. Detección de anomalías en el rodamiento DE del generador. Alarmas reales. Año 2013

-Modelo de comportamiento normal del rodamiento NDE del generador:




Figura 114. Modelo de SVM. Detección de anomalías en el rodamiento NDE del generador. Alarmas reales. Año 2013

-Modelo de comportamiento normal de la multiplicadora:

-Modelo de comportamiento normal de la temperatura del aceite de la multiplicadora:




Figura 115. Modelo de SVM. Detección de anomalías en el aceite de la multiplicadora. Alarmas reales. Año 2013

-Modelo de comportamiento normal del rodamiento de la multiplicadora:




Figura 116. Modelo de SVM. Detección de anomalías en el rodamiento de la multiplicadora. Alarmas reales. Año 2013

-Modelo de comportamiento normal del control del paso de pala:

-Modelo de comportamiento normal de la temperatura del aceite de la multiplicadora:




Figura 117. Modelo de SVM. Detección de anomalías en el ángulo de las palas. Alarmas reales. Año 2013

9.3.4 Año 2014

-Modelo de comportamiento normal del generador:

-Modelo de comportamiento normal de los anillos del generador:




Figura 118. Modelo de la red neuronal RBF. Detección de anomalías en los anillos del generador. Alarmas reales. Año 2014

-Modelo de comportamiento normal del rodamiento DE del generador:




Figura 119. Modelo de SVM. Detección de anomalías en el rodamiento DE del generador. Alarmas reales. Año 2014

-Modelo de comportamiento normal del rodamiento NDE del generador:




Figura 120. Modelo de SVM. Detección de anomalías en el rodamiento NDE del generador. Alarmas reales. Año 2014

-Modelo de comportamiento normal de la multiplicadora:

-Modelo de comportamiento normal de la temperatura del aceite de la multiplicadora:




Figura 121. Modelo de SVM. Detección de anomalías en el aceite de la multiplicadora. Alarmas reales. Año 2014

-Modelo de comportamiento normal del rodamiento de la multiplicadora:




Figura 122. Modelo de SVM. Detección de anomalías en el rodamiento de la multiplicadora. Alarmas reales. Año 2014

-Modelo de comportamiento normal del control del paso de pala:

-Modelo de comportamiento normal de la temperatura del aceite de la multiplicadora:




Figura 123. Modelo de SVM. Detección de anomalías en el ángulo de las palas. Alarmas reales. Año 2014

9.4 Utilizando todos los modelos de comportamiento

Una vez que se ha formado el detector de anomalías de cada uno de los modelos, se procede a estudiar los 3 detectores. Este proceso consiste en analizar la coincidencia de anomalías de dichos modelos.

De esta forma se puede realizar la toma de decisiones. Como se está estudiando la detección de anomalías para 3 modelos, si en un punto hay dos o más coincidencia de anomalías, se puede considerar que en ese punto habrá una coincidencia.

A continuación, se verán dos tipos de gráfica por detector de anomalías: En la primera se representa las anomalías que ve cada detector; y la segunda representa el número de detectores que ven cada anomalía (por lo tanto, los valores serán de 0 a 3). Cuando el valor de la gráfica es mayor, hay más probabilidad de que haya una anomalía.

8.4.1 Año 2011

-Modelo de comportamiento normal del generador:

-Modelo de comportamiento normal de los anillos del generador:




Figura 124. Todos los modelos. Detección de anomalías en los anillos del generador. Alarmas reales. Año 2011 (1)




Figura 125. Todos los modelos. Detección de anomalías en los anillos del generador. Alarmas reales. Año 2011 (2)

-Modelo de comportamiento normal del rodamiento DE del generador:






Figura 126. Todos los modelos. Detección de anomalías en el rodamiento DE del generador. Alarmas reales. Año 2011 (1)



**Figura 127. Todos los modelos. Detección de anomalías en el rodamiento DE del generador.
Alarmas reales. Año 2011 (2)**

-Modelo de comportamiento normal del rodamiento NDE del generador:



**Figura 128. Todos los modelos. Detección de anomalías en el rodamiento NDE del generador.
Alarmas reales. Año 2011 (1)**




Figura 129. Todos los modelos. Detección de anomalías en el rodamiento NDE del generador. Alarmas reales. Año 2011 (2)

-Modelo de comportamiento normal de la multiplicadora:

-Modelo de comportamiento normal de la temperatura del aceite de la multiplicadora:




Figura 130. Todos los modelos. Detección de anomalías en el aceite de la multiplicadora. Alarmas reales. Año 2011 (1)




Figura 131. Todos los modelos. Detección de anomalías en el aceite de la multiplicadora. Alarmas reales. Año 2011 (2)

-Modelo de comportamiento normal del rodamiento de la multiplicadora:




Figura 132. Todos los modelos. Detección de anomalías en el rodamiento de la multiplicadora. Alarmas reales. Año 2011 (1)




Figura 133. Todos los modelos. Detección de anomalías en el rodamiento de la multiplicadora. Alarmas reales. Año 2011 (2)

-Modelo de comportamiento normal del control del paso de pala:

-Modelo de comportamiento normal del ángulo de las palas:




Figura 134. Todos los modelos. Detección de anomalías en el ángulo de las palas. Alarmas reales. Año 2011 (1)




Figura 135. Todos los modelos. Detección de anomalías en el ángulo de las palas. Alarmas reales. Año 2011 (2)

9.4.2 Año 2012

-Modelo de comportamiento normal del generador:

-Modelo de comportamiento normal de los anillos del generador:




Figura 136. Todos los modelos. Detección de anomalías en los anillos del generador. Alarmas reales. Año 2012 (1)




Figura 137. Todos los modelos. Detección de anomalías en los anillos del generador. Alarmas reales. Año 2012 (2)

-Modelo de comportamiento normal del rodamiento DE del generador:






Figura 138. Todos los modelos. Detección de anomalías en el rodamiento DE del generador. Alarmas reales. Año 2012 (1)



**Figura 139. Todos los modelos. Detección de anomalías en el rodamiento DE del generador.
Alarmas reales. Año 2012 (2)**

-Modelo de comportamiento normal del rodamiento NDE del generador:



**Figura 140. Todos los modelos. Detección de anomalías en el rodamiento NDE del generador.
Alarmas reales. Año 2012 (1)**




Figura 141. Todos los modelos. Detección de anomalías en el rodamiento NDE del generador. Alarmas reales. Año 2012 (2)

-Modelo de comportamiento normal de la multiplicadora:

-Modelo de comportamiento normal de la temperatura del aceite de la multiplicadora:




Figura 142. Todos los modelos. Detección de anomalías en el aceite de la multiplicadora. Alarmas reales. Año 2012 (1)




Figura 143. Todos los modelos. Detección de anomalías en el aceite de la multiplicadora. Alarmas reales. Año 2012 (2)

-Modelo de comportamiento normal del rodamiento de la multiplicadora:




Figura 144. Todos los modelos. Detección de anomalías en el rodamiento de la multiplicadora. Alarmas reales. Año 2012 (1)




Figura 145. Todos los modelos. Detección de anomalías en el rodamiento de la multiplicadora. Alarmas reales. Año 2012 (2)

-Modelo de comportamiento normal del control del paso de pala:

-Modelo de comportamiento normal de la temperatura del aceite de la multiplicadora:




Figura 146. Modelo SVM. Detección de anomalías en el ángulo de las palas. Alarmas reales. Año 2012 (1)




Figura 147. Modelo SVM. Detección de anomalías en el ángulo de las palas. Alarmas reales. Año 2012 (2)

9.4.3 Año 2013

-Modelo de comportamiento normal del generador:

-Modelo de comportamiento normal de los anillos del generador:




Figura 148. Todos los modelos. Detección de anomalías en los anillos del generador. Alarmas reales. Año 2013 (1)




Figura 149. Todos los modelos. Detección de anomalías en los anillos del generador. Alarmas reales. Año 2013 (2)

-Modelo de comportamiento normal del rodamiento DE del generador:






Figura 150. Todos los modelos. Detección de anomalías en el rodamiento DE del generador. Alarmas reales. Año 2013 (1)



**Figura 151. Todos los modelos. Detección de anomalías en el rodamiento DE del generador.
Alarmas reales. Año 2013 (2)**

-Modelo de comportamiento normal del rodamiento NDE del generador:



**Figura 152. Todos los modelos. Detección de anomalías en el rodamiento NDE del generador.
Alarmas reales. Año 2013 (1)**




Figura 153. Todos los modelos. Detección de anomalías en el rodamiento NDE del generador. Alarmas reales. Año 2013 (2)

-Modelo de comportamiento normal de la multiplicadora:

-Modelo de comportamiento normal de la temperatura del aceite de la multiplicadora:




Figura 154. Todos los modelos. Detección de anomalías en el aceite de la multiplicadora. Alarmas reales. Año 2013 (1)




Figura 155. Todos los modelos. Detección de anomalías en el aceite de la multiplicadora. Alarmas reales. Año 2013 (2)

-Modelo de comportamiento normal del rodamiento de la multiplicadora:




Figura 156. Todos los modelos. Detección de anomalías en el rodamiento de la multiplicadora. Alarmas reales. Año 2013 (1)




Figura 157. Todos los modelos. Detección de anomalías en el rodamiento de la multiplicadora. Alarmas reales. Año 2013 (2)

-Modelo de comportamiento normal del control del paso de pala:

-Modelo de comportamiento normal de la temperatura del aceite de la multiplicadora:




Figura 158. Todos los modelos. Detección de anomalías en el ángulo de las palas. Alarmas reales. Año 2013 (1)




Figura 159. Todos los modelos. Detección de anomalías en el ángulo de las palas. Alarmas reales. Año 2013 (2)

9.2.4 Año 2014

-Modelo de comportamiento normal del generador:

-Modelo de comportamiento normal de los anillos del generador:




Figura 160. Todos los modelos. Detección de anomalías en los anillos del generador. Alarmas reales. Año 2014 (1)




Figura 161. Todos los modelos. Detección de anomalías en los anillos del generador. Alarmas reales. Año 2014 (2)

-Modelo de comportamiento normal del rodamiento DE del generador:




Figura 162. Todos los modelos. Detección de anomalías en el rodamiento DE del generador. Alarmas reales. Año 2014 (1)




Figura 163. Todos los modelos. Detección de anomalías en el rodamiento DE del generador. Alarmas reales. Año 2014 (2)

-Modelo de comportamiento normal del rodamiento NDE del generador:




Figura 164. Todos los modelos. Detección de anomalías en el rodamiento NDE del generador. Alarmas reales. Año 2014 (1)




Figura 165. Todos los modelos. Detección de anomalías en el rodamiento NDE del generador. Alarmas reales. Año 2014 (2)

-Modelo de comportamiento normal de la multiplicadora:

-Modelo de comportamiento normal de la temperatura del aceite de la multiplicadora:




Figura 166. Todos los modelos. Detección de anomalías en el aceite de la multiplicadora. Alarmas reales. Año 2014 (1)




Figura 167. Todos los modelos. Detección de anomalías en el aceite de la multiplicadora. Alarmas reales. Año 2014 (2)

-Modelo de comportamiento normal del rodamiento de la multiplicadora:




Figura 168. Todos los modelos. Detección de anomalías en el rodamiento de la multiplicadora. Alarmas reales. Año 2014 (1)




Figura 169. Todos los modelos. Detección de anomalías en el rodamiento de la multiplicadora. Alarmas reales. Año 2014 (2)

-Modelo de comportamiento normal del control del paso de pala:

-Modelo de comportamiento normal de la temperatura del aceite de la multiplicadora:




Figura 170. Todos los modelos. Detección de anomalías en el ángulo de las palas. Alarmas reales. Año 2014 (1)




Figura 171. Todos los modelos. Detección de anomalías en el ángulo de las palas. Alarmas reales. Año 2014 (2)

9.5 Conclusiones

Como se puede observar, en todos los modelos se pueden detectar las anomalías por la misma zona. Aun así, podemos llegar a la conclusión de que el modelo basado en la red neuronal RBF es más sensible, ya que detecta un mayor número de anomalías mientras que el modelo basado en SVM es el menos sensible, ya que detecta menos anomalías.

El objetivo al utilizar estas gráficas consiste en analizar la probabilidad de que en el aerogenerador las anomalías detectadas sean reales y no se deba a falsas alarmas. La forma de decidir si una anomalía es real o no, se mirará si la mayoría de los modelos lo detecta como anomalía.

Estos resultados se utilizarán para crear indicadores del estado de salud del aerogenerador que se está estudiando.

Capítulo 10

Comparación estadística de los detectores

Para una mejor visión de este estudio, se procede a comparar cada uno de los detectores como se hizo con los modelos estudiados. Se verá una tabla por cada año. Los histogramas de cada modelo se observarán en el Anexo VII como se dijo en el apartado anterior.

El código de colores que se utilizará será azul para que la red neuronal perceptrón multicapa, verde para la red neuronal RBF y rojo para el SVM.

10.1 Año 2011

Modelo	Media			Desviación típica			MSE		
	Perceptrón	RBF	SVM	Perceptrón	RBF	SVM	Perceptrón	RBF	SVM
Anillos del generador	0.3966	0.4147	0.5092	1.6816	1.7786	1.6251	2.9848	3.3353	2.9001
Rodamiento DE del generador	1.5506	1.4623	1.3039	3.1442	3.2429	3.1433	12.2903	12.6540	11.5800
Rodamiento NDE del generador	1.3707	1.3921	0.9939	3.9130	4.0729	3.9188	17.1895	18.5261	16.2894
Aceite de la multiplicadora	0.6858	0.7101	0.0908	2.0591	2.1876	2.0557	4.7100	5.2896	4.2341
Rodamiento de la multiplicadora	0.3972	0.3820	0.1219	1.9619	2.0666	2.0057	4.0067	4.4165	4.0373
Paso de las palas	0.1083	0.1256	0.2775	1.5794	1.6611	1.6591	2.5062	2.7747	2.8294

Tabla 2. Comparación estadística de las monitorizaciones del año 2011

10.2 Año 2012

Modelo	Media			Desviación típica			MSE		
	Perceptrón	RBF	SVM	Perceptrón	RBF	SVM	Perceptrón	RBF	SVM
Anillos del generador	-0.4037	-0.3824	-0.2989	1.8739	1.9587	1.8188	3.6744	3.9824	3.3972
Rodamiento DE del generador	0.8479	0.7587	0.6090	2.5462	2.6200	2.5200	7.2018	7.4396	6.7211
Rodamiento NDE del generador	2.8527	2.8698	2.4781	3.4344	3.5801	3.4161	19.9322	21.0521	17.8102
Aceite de la multiplicadora	1.6526	1.6822	1.0632	2.3150	2.4181	2.3614	8.0903	8.6749	6.7064
Rodamiento de la multiplicadora	0.5365	0.5213	0.2768	2.1705	2.2442	2.2806	4.9986	5.3081	5.2775
Paso de las palas	0.1414	0.1695	0.1217	1.7127	1.7390	1.7355	2.9533	3.0528	3.1066

Tabla 3. Comparación estadística de las monitorizaciones del año 2012

10.3 Año 2013

Modelo	Media			Desviación típica			MSE		
	Perceptrón	RBF	SVM	Perceptrón	RBF	SVM	Perceptrón	RBF	SVM
Anillos del generador	-0.0798	-0.0783	0.0759	2.1205	2.1863	2.0419	4.5026	4.7858	4.1750
Rodamiento DE del generador	0.4614	0.3472	0.2866	2.9259	2.9876	2.8802	8.7735	9.0456	8.3773
Rodamiento NDE del generador	2.0438	2.0874	1.7798	3.6349	3.7686	3.6282	17.3891	18.5590	16.3311
Aceite de la multiplicadora	1.7900	1.8328	1.2581	2.6667	2.7219	2.7706	10.3149	10.7672	9.2583
Rodamiento de la multiplicadora	0.3912	0.3892	0.2089	2.4442	2.4733	2.5928	6.1268	6.2686	6.7660
Paso de las palas	0.1065	0.1935	0.3022	1.8139	1.8876	1.8773	3.3013	3.6004	3.6141

Tabla 4. Comparación estadística de las monitorizaciones del año 2013

10.4 Año 2014

Modelo	Media			Desviación típica			MSE		
	Perceptrón	RBF	SVM	Perceptrón	RBF	SVM	Perceptrón	RBF	SVM
Anillos del generador	-2.6322	-2.5218	-2.4792	1.8843	1.8971	1.6240	10.4788	9.9582	8.7835
Rodamiento DE del generador	0.7285	0.6909	0.5172	2.7823	2.8734	2.6963	8.2716	8.7335	7.5374
Rodamiento NDE del generador	-1.0060	-0.9648	-1.4240	3.7573	3.8989	3.6760	15.1282	16.1316	15.5397
Aceite de la multiplicadora	2.4371	2.4299	1.8298	2.3851	2.4677	2.4409	11.6278	11.9935	9.3062
Rodamiento de la multiplicadora	1.0031	1.0176	0.7551	2.1679	2.2501	2.3300	5.7055	6.0980	5.9988
Paso de las palas	-0.0409	0.0227	0.1153	1.8135	1.8086	1.8683	3.2901	3.2714	3.5038

Tabla 5. Comparación estadística de las monitorizaciones del año 2014

10.5 Conclusiones

Lo que más destaca de estos valores estadísticos es que la media deja de considerarse nula. Eso implica que la media obtenida es un valor característico para analizar la condición del estado de cada modelo durante cada uno de los años de estudio. Por lo tanto, los valores que se van a observar con más atención serán la media y el error cuadrático medio (MSE).

A diferencia de los resultados en los modelos de comportamiento normal, habrá menor MSE al usar los modelos basados en SVM en la mayor parte de los modelos (excepto en el rodamiento de la multiplicadora en 2013). Habrá mayor MSE en los modelos basados en una red neuronal RBF, excepto en los anillos del generador y el paso de pala del año 2014.

La media no es un factor útil para deducir el patrón de cada modelo. Lo que se puede observar sobre ella es que a medida mayor sean los años, el valor absoluto de la media tiende a ser mayor. Eso es debido a que cuanto mayor sea el tiempo de vida de un aerogenerador menor será su fiabilidad y por lo tanto sus componentes tendrán más anomalías.

A partir de estos datos, se puede deducir que el modelo que probablemente encuentre mayores anomalías sería el basado de la red neuronal RBF, seguido por el de la red neuronal perceptrón multicapa y por último será aquel basado en las máquinas de vectores soporte (SVM). También se prevé mayores anomalías a medida que pase el tiempo.

Capítulo 11

Indicadores de comportamientos anómalos

Por último, una vez estudiado los modelos de comportamiento normal y visto las gráficas con las anomalías detectadas por cada año se pretende realizar una propuesta de indicadores del estado de salud del aerogenerador. Los modelos en los que se va a realizar dicha propuesta son, como se había explicado antes, el modelo del generador, el de la multiplicadora y el del control de paso de pala.

Para ello, se ha creado un programa que detecte el número de anomalías por día durante los años de monitorización y se representen mediante una gráfica. Los años de monitorización son el año 2011, 2012, 2013 y 2014. Ese periodo de tiempo es equivalente a 1277 muestras.

Los códigos utilizados se encuentran en el anexo IX.

A continuación, se representará las gráficas antes mencionadas. Se dividirán por herramientas utilizadas y por modelos de estudio.

En cada gráfica se verán diferenciado los años a los que representa.

11.1 Utilizando el modelo de comportamiento normal de la red neuronal perceptrón multicapa

-Modelo de comportamiento normal del generador:

La gráfica que representa el estado de salud del generador es la siguiente:




Figura 172. Perceptrón multicapa. Representación del número de anomalías por día. Modelo del generador

El generador se divide en los siguientes subcomponentes:

-Modelo de comportamiento normal de los anillos del generador:




Figura 173. Perceptrón multicapa. Representación del número de anomalías por día. Modelo de los anillos del generador

-Modelo de comportamiento normal del rodamiento DE del generador:




Figura 174. Perceptrón multicapa. Representación del número de anomalías por día. Modelo del rodamiento DE del generador

-Modelo de comportamiento normal del rodamiento NDE del generador:




Figura 175. Perceptrón multicapa. Representación del número de anomalías por día. Modelo del rodamiento NDE del generador

-Modelo de comportamiento normal de la multiplicadora:

La gráfica que representa el estado de salud de la multiplicadora es la siguiente:




Figura 176. Perceptrón multicapa. Representación del número de anomalías por día. Modelo de la multiplicadora

La multiplicadora se divide en los siguientes subcomponentes:

-Modelo de comportamiento normal del aceite de la multiplicadora:




Figura 177. Perceptrón multicapa. Representación del número de anomalías por día. Modelo del aceite de la multiplicadora

-Modelo de comportamiento normal del rodamiento de la multiplicadora:




Figura 178. Perceptrón multicapa. Representación del número de anomalías por día. Modelo del rodamiento de la multiplicadora

-Modelo de comportamiento normal del control del paso de pala:

El control del paso de pala solo tiene un único componente:

-Modelo de comportamiento normal del ángulo de las palas:




Figura 179. Perceptrón multicapa. Representación del número de anomalías por día. Modelo del paso de pala

11.2 Utilizando el modelo de comportamiento normal de la red neuronal RBF

-Modelo de comportamiento normal del generador:

La gráfica que representa el estado de salud del generador es la siguiente:




Figura 180. RBF. Representación del número de anomalías por día. Modelo del generador

El generador se divide en los siguientes subcomponentes:

-Modelo de comportamiento normal de los anillos del generador:




Figura 181. RBF. Representación del número de anomalías por día. Modelo de los anillos del generador

-Modelo de comportamiento normal del rodamiento DE del generador:




Figura 182. RBF. Representación del número de anomalías por día. Modelo del rodamiento DE del generador

-Modelo de comportamiento normal del rodamiento NDE del generador:




Figura 183. RBF. Representación del número de anomalías por día. Modelo del rodamiento NDE del generador

-Modelo de comportamiento normal de la multiplicadora:

La gráfica que representa el estado de salud de la multiplicadora es la siguiente:




Figura 184. RBF. Representación del número de anomalías por día. Modelo de la multiplicadora

La multiplicadora se divide en los siguientes subcomponentes:

-Modelo de comportamiento normal del aceite de la multiplicadora:




Figura 185. RBF. Representación del número de anomalías por día. Modelo del aceite de la multiplicadora

-Modelo de comportamiento normal del rodamiento de la multiplicadora:




Figura 186. RBF. Representación del número de anomalías por día. Modelo del rodamiento de la multiplicadora

-Modelo de comportamiento normal del control del paso de pala:

El control del paso de pala solo tiene un único componente:

-Modelo de comportamiento normal del ángulo de las palas:




Figura 187. RBF. Representación del número de anomalías por día. Modelo del paso de pala

11.3 Utilizando el modelo de comportamiento normal del SVM

-Modelo de comportamiento normal del generador:

La gráfica que representa el estado de salud del generador es la siguiente:




Figura 188. SVM. Representación del número de anomalías por día. Modelo del generador

El generador se divide en los siguientes subcomponentes:

-Modelo de comportamiento normal de los anillos del generador:




Figura 189. SVM. Representación del número de anomalías por día. Modelo de los anillos del generador

-Modelo de comportamiento normal del rodamiento DE del generador:




Figura 190. RBF. Representación del número de anomalías por día. Modelo del rodamiento DE del generador

-Modelo de comportamiento normal del rodamiento NDE del generador:




Figura 191. SVM. Representación del número de anomalías por día. Modelo del rodamiento NDE del generador

-Modelo de comportamiento normal de la multiplicadora:

La gráfica que representa el estado de salud de la multiplicadora es la siguiente:




Figura 192. SVM. Representación del número de anomalías por día. Modelo de la multiplicadora

La multiplicadora se divide en los siguientes subcomponentes:

-Modelo de comportamiento normal del aceite de la multiplicadora:




Figura 193. SVM. Representación del número de anomalías por día. Modelo del aceite de la multiplicadora

-Modelo de comportamiento normal del rodamiento de la multiplicadora:




Figura 194. SVM. Representación del número de anomalías por día. Modelo del rodamiento de la multiplicadora

-Modelo de comportamiento normal del control del paso de pala:

El control del paso de pala solo tiene un único componente:

-Modelo de comportamiento normal del ángulo de las palas:




Figura 195. RBF. Representación del número de anomalías por día. Modelo del paso de pala

11.4 Utilizando todos los modelos basados en las distintas herramientas de aprendizaje automatizado. Decisión final

Una vez ya representadas todas las gráficas de cada modelo basado en cada una de las herramientas (red neuronal perceptrón multicapa, red neuronal RBF y máquina de soporte vectorial, SVM), se procede a analizar cuál de las anomalías correspondientes a ese modelo serán alarmas reales o falsas alarmas. Para ello se utilizará un programa en el cual, si 2 o más modelos detectan alarma en un punto, en ese punto habrá alarma real. Si hay una o menos detecciones en ese punto, no habrá alarma.

El código en el que detectan las alarmas reales se encuentra en el apartado VIII, en donde se hacen las detecciones en todos los modelos.

A continuación, se mostrarán las gráficas que representa el número de anomalías reales.

-Modelo de comportamiento normal del generador:

La gráfica que representa el estado de salud del generador es la siguiente:




Figura 196. Decisión final. Representación del número de anomalías por día. Modelo del generador

El generador se divide en los siguientes subcomponentes:

-Modelo de comportamiento normal de los anillos del generador:




Figura 197. Decisión final. Representación del número de anomalías por día. Modelo de los anillos del generador

-Modelo de comportamiento normal del rodamiento DE del generador:




Figura 198. Decisión final. Representación del número de anomalías por día. Modelo del rodamiento DE del generador

-Modelo de comportamiento normal del rodamiento NDE del generador:




Figura 199. Decisión final. Representación del número de anomalías por día. Modelo del rodamiento NDE del generador

-Modelo de comportamiento normal de la multiplicadora:

La gráfica que representa el estado de salud de la multiplicadora es la siguiente:




Figura 200. Decisión final. Representación del número de anomalías por día. Modelo de la multiplicadora

La multiplicadora se divide en los siguientes subcomponentes:

-Modelo de comportamiento normal del aceite de la multiplicadora:




Figura 201. Decisión final. Representación del número de anomalías por día. Modelo del aceite de la multiplicadora

-Modelo de comportamiento normal del rodamiento de la multiplicadora:




Figura 202. Decisión final. Representación del número de anomalías por día. Modelo del rodamiento de la multiplicadora

-Modelo de comportamiento normal del control del paso de pala:

El control del paso de pala solo tiene un único componente:

-Modelo de comportamiento normal del ángulo de las palas:




Figura 203. Decisión final. Representación del número de anomalías por día. Modelo del paso de pala

11.5 Índice de anomalías por unidad de tiempo

Una vez obtenido las anomalías detectadas por día y representarlas, se decidió hallar un índice con el fin de evaluar mejor los resultados. Este índice consiste en el número de anomalías por unidad de tiempo, en este caso por mes. A continuación, se mostrará en unas tablas los índices resultantes. Los más relevantes, que son aquellos obtenidos utilizando los 3 modelos estarán marcados en amarillo.

- a) Para el modelo basado en una red neuronal perceptrón multicapa (anomalías/mes):

Modelo	Año			
	2011	2012	2013	2014
Generador	200.42	247.67	209.67	517.78
Anillos del generador	71.33	75.08	66.00	370.00
Rodamiento DE	61.83	55.08	65.83	76.33
Rodamiento NDE	67.25	117.50	77.83	71.44
Multiplicadora	124.00	169.08	180.42	320.67
Aceite multiplicadora	61.50	112.67	115.50	219.50
Rodamiento multiplicadora	62.50	56.92	64.92	101.11
Control paso de pala	2.67	2.50	4.75	39.44

Tabla 6. Anomalías detectadas por unidad de tiempo. Modelos basados en una red neuronal perceptrón multicapa

- b) Para el modelo basado en una red neuronal RBF (anomalías/mes):

Modelo	Año			
	2011	2012	2013	2014
Generador	167.50	205.33	182.25	474.00
Anillos del generador	53.83	66.75	59.50	352.00
Rodamiento DE	56.42	46.42	56.58	60.89
Rodamiento NDE	57.33	92.17	66.17	61.11
Multiplicadora	103.50	140.42	160.08	282.89
Aceite multiplicadora	48.92	89.50	101.42	209.11
Rodamiento multiplicadora	54.58	50.92	58.67	73.78
Control paso de pala	2.50	2.58	5.17	32.44

Tabla 7. Anomalías detectadas por unidad de tiempo. Modelos basados en una red neuronal RBF

c) Para el modelo basado en SVM (anomalías/mes):

Modelo	Año			
	2011	2012	2013	2014
Generador	223.58	236.83	218.08	633.78
Anillos del generador	84.67	73.67	70.75	469.78
Rodamiento DE	66.17	61.83	70.25	72.22
Rodamiento NDE	72.75	101.33	77.08	91.78
Multiplicadora	155.83	172.50	188.00	283.99
Aceite multiplicadora	79.17	106.33	115.50	180.33
Rodamiento multiplicadora	76.67	66.17	72.50	103.56
Control paso de pala	2.33	2.33	4.67	32.67

Tabla 8. Anomalías detectadas por unidad de tiempo. Modelos basados SVM

d) Utilizando los 3 modelos (anomalías/mes):

Modelo	Año			
	2011	2012	2013	2014
Generador	239.17	197.33	254.50	516.00
Anillos del generador	41.50	69.50	95.75	348.56
Rodamiento DE	107.92	47.58	83.00	83.33
Rodamiento NDE	89.75	80.25	75.75	84.11
Multiplicadora	85.83	137.50	256.80	282.44
Aceite multiplicadora	38.75	81.00	153.83	193.56
Rodamiento multiplicadora	47.08	56.50	96.25	88.89
Control paso de pala	2.83	5.92	8.58	41.56

Tabla 9. Anomalías detectadas por unidad de tiempo. Utilizando todos los modelos

Para obtener el número de anomalías por mes en cada año se ha utilizado un programa para calcular todas las anomalías en cada mes y después se calculó el promedio al año. Se puede ver ese programa en el anexo IX.

11.6 Conclusiones

Para terminar, se estudiará las anomalías en los componentes principales: el generador, la multiplicadora y el control del paso de pala.

A nivel global se puede observar que a medida que pase el tiempo, el número de anomalías aumenta. Eso es debido a que cuanto más tiempo ha vivido el aerogenerador, más stress ha sufrido a lo largo de su vida y por lo tanto tendrá más comportamientos inesperados o anómalos.

En cuanto al control del paso de pala, las anomalías no son muy frecuentes, por lo tanto, no habrá que preocuparse en gran magnitud por el mantenimiento, excepto en el año 2014, que llega a haber más de 120 anomalías por día en unos pocos días, eso equivale a aproximadamente 2 horas de anomalías, ya que los datos se tomaron cada 10 minutos. Por otro lado, tanto en el generador como en la multiplicadora la media de anomalías aumenta a medida que pase el tiempo. El generador llega a las 140 anomalías por día, mientras que la multiplicadora a 80, que no es tanto, pero hay que tener en cuenta que estos valores se mantienen constantes, por lo que habrá que preocuparse por el mantenimiento del generador y la multiplicadora del aerogenerador.

Capítulo 12

Conclusión

Este proyecto consistía en estudiar el estado de salud de un aerogenerador real. Los componentes que se estudian son el generador, la multiplicadora y el control de paso de pala. El estado de salud se ha estudiado mediante modelos de comportamiento normal basados en herramientas de aprendizaje automatizado. Dichas herramientas se tratan de redes neuronales perceptrón multicapa, redes neuronales RBF y máquinas de soporte vectorial (SVM).

Se presentan los modelos de comportamiento normal a partir de un año escogido como referencia. Ese año se denomina conjunto de entrenamiento. El año que se pensó al principio para que sea el conjunto de entrenamiento era el primer año del que se tenía datos (2009), ya que cuanto más “joven” sea el aerogenerador tiende más a tener un patrón de comportamiento normal. Se acabó descartando esa idea ya que las muestras obtenidas después del filtrado eran inferiores durante el año 2009 que durante los demás años y por lo tanto se escogió el del año 2010 porque al haber más muestras, la herramienta de aprendizaje tendrá más información para crear un modelo más fiable.

Estos modelos de comportamiento son creados para predecir lo que sería un comportamiento esperado por parte de la componente del aerogenerador. La aplicación real sería que, una vez obtenido un modelo de comportamiento fiable, un sensor estaría detectando datos cada 10 minutos. Cuando se detecten anomalías continuadas durante un día, el modelo daría una alarma y se mirará el mantenimiento de dicho componente.

Este modelo es muy fiable no solo para ver si hay anomalías en el aerogenerador, sino también los componentes que tienen un comportamiento inesperado y por lo tanto habría que cambiar o arreglar.

Bibliografía

- [1] **Eurosat.** *Estadísticas de las energías renovables.*
- [2] **Opex Energy.** *Energía eólica. Tren de Potencia y Multiplicador*
- [3] **Abengoa.** *Energía eólica.*
- [4] **Sotaventogalicia.** *Instalaciones eólicas. Funcionamiento.*
- [5] **AEE Asociación Empresarial Eólica.** *Energía eólica en España*
- [6] **Ángel Gil, Miguel Ángel Sanz Bobi.** *Behavior anomaly indicators based on reference patterns - application to the gearbox and electrical generator of a wind turbine*
- [7] **UC3M, RAI 2012.** *Redes de Neuronas Artificiales*
- [8] **Ibiblio.** *Redes de función de base radial (RBF).*
- [9] **Alba Castro, José Luis.** *Máquina de Vectores Soporte*

Anexos

Anexo I – Gráficas del Primer filtrado

a) Filtrados del 2009

-Temperatura del aceite de la multiplicadora:




Figura 204. Primer Filtrado datos del 2009. Temperatura del aceite de la multiplicadora

-Temperatura de los anillos del generador




Figura 205. Primer Filtrado datos del 2009. Temperatura de los anillos del generador

-Ángulo de las palas:




Figura 206. Primer Filtrado datos del 2009. Ángulo de las palas

-Temperatura del rodamiento DE del generador




Figura 207. Primer Filtrado datos del 2009. Temperatura del rodamiento DE del generador

-Temperatura del rodamiento NDE del generador:




Figura 208. Primer Filtrado datos del 2009. Temperatura del rodamiento NDE del generador

-Temperatura del rodamiento de la multiplicadora:




Figura 209. Primer Filtrado datos del 2009. Temperatura del rodamiento de la multiplicadora

-Temperatura interior de la góndola:




Figura 210. Primer Filtrado datos del 2009. Temperatura del interior de la góndola

-Potencia total generada:




Figura 211. Primer Filtrado datos del 2009. Potencia total generada

-Velocidad del viento:




Figura 212. Primer Filtrado datos del 2009. Velocidad del viento

-Ángulo del viento:




Figura 213. Primer Filtrado datos del 2009. Ángulo del viento

b) Filtrados del 2010

-Temperatura del aceite de la multiplicadora:




Figura 214. Primer Filtrado datos del 2010. Temperatura del aceite de la multiplicadora

-Temperatura de los anillos del generador




Figura 215. Primer Filtrado datos del 2010. Temperatura de los anillos del generador

-Ángulo de las palas:




Figura 216. Primer Filtrado datos del 2010. Ángulo de las palas

-Temperatura del rodamiento DE del generador




Figura 217. Primer Filtrado datos del 2010. Temperatura del rodamiento DE del generador

-Temperatura del rodamiento NDE del generador:




Figura 218. Primer Filtrado datos del 2010. Temperatura del rodamiento NDE del generador

-Temperatura del rodamiento de la multiplicadora:




Figura 219. Primer Filtrado datos del 2010. Temperatura del rodamiento de la multiplicadora

-Temperatura interior de la góndola:




Figura 220. Primer Filtrado datos del 2010. Temperatura del interior de la góndola

-Potencia total generada:




Figura 221. Primer Filtrado datos del 2010. Potencia total generada

-Velocidad del viento:




Figura 222. Primer Filtrado datos del 2010. Velocidad del viento

-Ángulo del viento:




Figura 223. Primer Filtrado datos del 2010. Ángulo del viento

Anexo II – Gráficas del segundo filtrado

a) Filtrados del 2009

-Temperatura del aceite de la multiplicadora:




Figura 224. Segundo Filtrado datos del 2009. Temperatura del aceite de la multiplicadora

-Temperatura de los anillos del generador




Figura 225. Segundo Filtrado datos del 2009. Temperatura de los anillos del generador

-Ángulo de las palas:




Figura 226. Segundo Filtrado datos del 2009. Ángulo de las palas

-Temperatura del rodamiento DE del generador




Figura 227. Segundo Filtrado datos del 2009. Temperatura del rodamiento DE del generador

-Temperatura del rodamiento NDE del generador:




Figura 228. Segundo Filtrado datos del 2009. Temperatura del rodamiento NDE del generador

-Temperatura del rodamiento de la multiplicadora:




Figura 229. Segundo Filtrado datos del 2009. Temperatura del rodamiento de la multiplicadora

-Temperatura interior de la góndola:




Figura 230. Segundo Filtrado datos del 2009. Temperatura del interior de la góndola

-Potencia total generada:




Figura 231. Segundo Filtrado datos del 2009. Potencia total generada

-Velocidad del viento:




Figura 232. Segundo Filtrado datos del 2009. Velocidad del viento

-Ángulo del viento:




Figura 233. Segundo Filtrado datos del 2009. Ángulo del viento

b) Filtrados del 2010

-Temperatura del aceite de la multiplicadora:




Figura 234. Segundo Filtrado datos del 2010. Temperatura del aceite de la multiplicadora

-Temperatura de los anillos del generador




Figura 235. Segundo Filtrado datos del 2010. Temperatura de los anillos del generador

-Ángulo de las palas:




Figura 236. Segundo Filtrado datos del 2010. Ángulo de las palas

-Temperatura del rodamiento DE del generador




Figura 237. Segundo Filtrado datos del 2010. Temperatura del rodamiento DE del generador

-Temperatura del rodamiento NDE del generador:




Figura 238. Segundo Filtrado datos del 2010. Temperatura del rodamiento NDE del generador

-Temperatura del rodamiento de la multiplicadora:




Figura 239. Segundo Filtrado datos del 2010. Temperatura del rodamiento de la multiplicadora

-Temperatura interior de la góndola:




Figura 240. Segundo Filtrado datos del 2010. Temperatura del interior de la góndola

-Potencia total generada:




Figura 241. Segundo Filtrado datos del 2010. Potencia total generada

-Velocidad del viento:




Figura 242. Segundo Filtrado datos del 2010. Velocidad del viento

-Ángulo del viento:




Figura 243. Segundo Filtrado datos del 2010. Ángulo del viento

Anexo III – Códigos de filtrado utilizados

-Año 2009

```
clc
clear
%Este script eliminará todos los datos que sean negativos (excepto la
temperatura ambiental) o tengan el valor
%NAN (Not a number)
load('alldata.mat') %se carga el programa con todos los datos
%comienza el bloque que analizará todos los datos
i=1;

for k=1:5508

if(alldata.aero.tem_rod_alta_multi.val(k)>55&alldata.aero.tem_rod_alta
_multi.val(k)<80)&(alldata.aero.tem_aceite_multi.val(k)>45&alldata.aer
o.tem_aceite_multi.val(k)<75)&(alldata.aero.tem_rod_DE_gen.val(k)>25&a
lldata.aero.tem_rod_DE_gen.val(k)<60)&(alldata.aero.tem_rod_NDE_gen.va
l(k)>25&alldata.aero.tem_rod_NDE_gen.val(k)<60)&(alldata.aero.tem_anil
los_sld_gen.val(k)>5&alldata.aero.tem_anillos_sld_gen.val(k)<30)&(alld
ata.aero.tem_interior_nac.val(k)>0)&(alldata.aero.pot_total.val(k)>0)&
(alldata.aero.vel_viento.val(k)>0)&(alldata.aero.angulo_palas.val(k)>0
&alldata.aero.angulo_palas.val(k)<45)&(alldata.aero.angulo_viento.val(
k)>-45&alldata.aero.angulo_viento.val(k)<45)

filtrado2009_tem_rod_alta_multi(i,1)=alldata.aero.tem_rod_alta_multi.v
al(k);

filtrado2009_tem_aceite_multi(i,1)=alldata.aero.tem_aceite_multi.val(k
);

filtrado2009_tem_rod_DE_gen(i,1)=alldata.aero.tem_rod_DE_gen.val(k);

filtrado2009_tem_rod_NDE_gen(i,1)=alldata.aero.tem_rod_NDE_gen.val(k);

filtrado2009_tem_anillos_sld_gen(i,1)=alldata.aero.tem_anillos_sld_gen
.val(k);

filtrado2009_tem_interior_nac(i,1)=alldata.aero.tem_interior_nac.val(k
);

filtrado2009_pot_total(i,1)=alldata.aero.pot_total.val(k);

filtrado2009_vel_viento(i,1)=alldata.aero.vel_viento.val(k);

filtrado2009_angulo_viento(i,1)=alldata.aero.angulo_viento.val(k);

filtrado2009_angulo_palas(i,1)=alldata.aero.angulo_palas.val(k);
    fecha2009_filtrado(i,1)=alldata.fecha(k);
    date=datevec(fecha2009_filtrado(i,1));
    filtrado2009_fecha_conv(i,1)=date(3);
    filtrado2009_fecha_conv(i,2)=date(2);
    filtrado2009_fecha_conv(i,3)=date(1);
    filtrado2009_fecha_conv(i,4)=date(4);
    filtrado2009_fecha_conv(i,5)=date(5);
    filtrado2009_fecha_conv(i,6)=date(6);
    i=i+1;
end
end
```

-Año 2010

clc

clear

%Este script eliminará todos los datos que sean negativos (excepto la temperatura ambiental) o tengan el valor

%NAN (Not a number)

load('alldata.mat') %se carga el programa con todos los datos

%comienza el buque que analizará todos los datos

i=1;

for k=5509:107568

if(alldata.aero.tem_rod_alta_multi.val(k)>55&alldata.aero.tem_rod_alta_multi.val(k)<80)&(alldata.aero.tem_aceite_multi.val(k)>45&alldata.aero.tem_aceite_multi.val(k)<75)&(alldata.aero.tem_rod_DE_gen.val(k)>25&alldata.aero.tem_rod_DE_gen.val(k)<60)&(alldata.aero.tem_rod_NDE_gen.val(k)>25&alldata.aero.tem_rod_NDE_gen.val(k)<60)&(alldata.aero.tem_anillos_sld_gen.val(k)>5&alldata.aero.tem_anillos_sld_gen.val(k)<30)&(alldata.aero.tem_interior_nac.val(k)>0)&(alldata.aero.pot_total.val(k)>0)&(alldata.aero.vel_viento.val(k)>0)&(alldata.aero.angulo_palas.val(k)>0&alldata.aero.angulo_palas.val(k)<45)&(alldata.aero.angulo_viento.val(k)>-45&alldata.aero.angulo_viento.val(k)<45)

filtrado2010_tem_rod_alta_multi(i,1)=alldata.aero.tem_rod_alta_multi.val(k);

filtrado2010_tem_aceite_multi(i,1)=alldata.aero.tem_aceite_multi.val(k);

filtrado2010_tem_rod_DE_gen(i,1)=alldata.aero.tem_rod_DE_gen.val(k);

filtrado2010_tem_rod_NDE_gen(i,1)=alldata.aero.tem_rod_NDE_gen.val(k);

filtrado2010_tem_anillos_sld_gen(i,1)=alldata.aero.tem_anillos_sld_gen.val(k);

filtrado2010_tem_interior_nac(i,1)=alldata.aero.tem_interior_nac.val(k);

filtrado2010_pot_total(i,1)=alldata.aero.pot_total.val(k);

filtrado2010_vel_viento(i,1)=alldata.aero.vel_viento.val(k);

filtrado2010_angulo_viento(i,1)=alldata.aero.angulo_viento.val(k);

filtrado2010_angulo_palas(i,1)=alldata.aero.angulo_palas.val(k);

fecha2010_filtrado(i,1)=alldata.fecha(k);

date=datevec(fecha2010_filtrado(i,1));

filtrado2010_fecha_conv(i,1)=date(3);

filtrado2010_fecha_conv(i,2)=date(2);

filtrado2010_fecha_conv(i,3)=date(1);

filtrado2010_fecha_conv(i,4)=date(4);

filtrado2010_fecha_conv(i,5)=date(5);

filtrado2010_fecha_conv(i,6)=date(6);

i=i+1;

end

end

Anexo IV – Códigos para la creación de modelos de comportamiento normal basados en las redes neuronales perceptrón multicapa

-Aceite de la multiplicadora:

```
clear all
close all
clc
```

```
load('filtrado2010_tem_aceite_multi.mat');
load('filtrado2010_tem_interior_nac.mat');
load('filtrado2010_pot_total.mat');
load('filtrado2010_vel_viento.mat');
```

```
[nsamples m]=size(filtrado2010_tem_aceite_multi);
t=1:nsamples;
```

```
%plot(t, data(:,1), t, data(:,2), t, data(:,3))
```

```
figure(1)
plot(t, filtrado2010_tem_aceite_multi, t,
filtrado2010_tem_interior_nac, t, filtrado2010_pot_total, t,
filtrado2010_vel_viento)
ylabel('Magnitude'); xlabel('Sample');
legend('tem_aceite_multi', 'tem_interior_nac', 'pot_total',
'vel_viento');
title(' Variables');
```

```
training=nsamples;
X=zeros(training,3); %Only first training input samples
X(:,1)=filtrado2010_tem_interior_nac(1:training);
X(:,2)=filtrado2010_pot_total(1:training);
X(:,3)=filtrado2010_vel_viento(1:training);
```

```
T=zeros(training,1); %Only first training target output samples
T(:,1)=filtrado2010_tem_aceite_multi(1:training,1);
```

```
%T(:,2)=data(1:june,9); %oil pressure guide vane position
%T=data(1:june,9); %pressure guide vane position
T=T';
X=X';
%
%
net_aceite_multi = feedforwardnet([50 50], 'trainlm');
net_aceite_multi = configure(net_aceite_multi,X,T);
```

```
%Criteria for splitting the training set
```

```

net_aceite_multi.divideFcn='dividerand';
net_aceite_multi.divideParam.trainRatio = 70/100;
net_aceite_multi.divideParam.valRatio = 15/100;
net_aceite_multi.divideParam.testRatio = 15/100;

% Inicialización de pesos
net_aceite_multi=init(net_aceite_multi);
% Se ajustan diversos parámetros del entrenamiento

net_aceite_multi.trainParam.epochs = 10000;
net_aceite_multi.trainParam.lr = 0.002;
net_aceite_multi.trainParam.show = 50;
net_aceite_multi.trainParam.goal = 1e-5;
net_aceite_multi.trainParam.max_fail =40; % Failures allowed in
validation

[net_aceite_multi, traza] = train(net_aceite_multi,X,T);
%view(net)
Yp = net_aceite_multi(X);
perf = perform(net_aceite_multi,Yp,X);

%Training error representation
figure(2)
plot(traza.epoch, traza.perf, traza.epoch, traza.vperf, traza.epoch,
traza.tperf);
legend('training', 'Validation', 'Test');
ylabel('Cuadratic Error');
xlabel('Epoch');

%Prediction of the NN with training set

P = sim(net_aceite_multi,X);

% Representation predicted and real values in the output

figure(3);
%plot(X,T, 'sr',X,Z,'X')
plot(1:training, T(1,:),1:training, P(1,:))
ylabel('Temp Bearing'); xlabel('Sample');
legend('Real Value', 'Estimated Value');
title(' Neural network test using the training set');

figure(4)
histogram(T(1,:)-P(1,:))
ylabel('Frecuency'); xlabel('Samples');
title(' Histogram of error with training data');
dt_aceite_multi=std(T-P);
media_aceite_multi=mean(T-P);
error_cuadratico_aceite_multi=mse(T-P);

```

-Anillos del generador:

```
clear all
close all
```

```
load('filtrado2010_tem_anillos_sld_gen.mat');
load('filtrado2010_tem_interior_nac.mat');
load('filtrado2010_pot_total.mat');
load('filtrado2010_vel_viento.mat');
```

```
%[nsamples m]=size(data);
```

```
[nsamples m]=size(filtrado2010_tem_anillos_sld_gen);
t=1:nsamples;
```

```
%plot(t, data(:,1), t, data(:,2), t, data(:,3))
```

```
figure(1)
plot(t, filtrado2010_tem_anillos_sld_gen, t,
filtrado2010_tem_interior_nac, t, filtrado2010_pot_total, t,
filtrado2010_vel_viento)
ylabel('Magnitude'); xlabel('Sample');
legend('tem_anillos_sld_gen', 'tem_interior_nac', 'pot_total',
'vel_viento');
title(' Variables');
```

```
training=nsamples;
X=zeros(training,3); %Only first training input samples
X(:,1)=filtrado2010_tem_interior_nac(1:training);
X(:,2)=filtrado2010_pot_total(1:training);
X(:,3)=filtrado2010_vel_viento(1:training);

T=zeros(training,1); %Only first training target output samples
T(:,1)=filtrado2010_tem_anillos_sld_gen(1:training,1);

%T(:,2)=data(1:june,9); %oil pressure guide vane position
%T=data(1:june,9); %pressure guide vane position
T=T';
X=X';
```

```
net_anillosgen = feedforwardnet([50 49],'trainlm');
net_anillosgen = configure(net_anillosgen,X,T);
```

```
%Criteria for splitting the training set
```

```
net_anillosgen.divideFcn='dividerand';
net_anillosgen.divideParam.trainRatio = 70/100;
net_anillosgen.divideParam.valRatio = 15/100;
net_anillosgen.divideParam.testRatio = 15/100;
```

```
% Inicialización de pesos
```

```

net_anillosgen=init(net_anillosgen);
% Se ajustan diversos parámetros del entrenamiento

net_anillosgen.trainParam.epochs = 10000;
net_anillosgen.trainParam.lr = 0.002;
net_anillosgen.trainParam.show = 50;
net_anillosgen.trainParam.goal = 1e-5;
net_anillosgen.trainParam.max_fail =40; % Failures allowed in
validation

[net_anillosgen, traza] = train(net_anillosgen,X,T);
%view(net)
Yp = net_anillosgen(X);
perf = perform(net_anillosgen,Yp,X);

% Training error representation
figure(2)
plot(traza.epoch, traza.perf, traza.epoch, traza.vperf, traza.epoch,
traza.tperf);
legend('training', 'Validation', 'Test');
ylabel('Cuadratic Error');
xlabel('Epoch');

% Prediction of the NN with training set

P = sim(net_anillosgen,X);

% Representation predicted and real values in the output

figure(3);
%plot(X,T, 'sr',X,Z,'X')
plot(1:training, T(1,:),1:training, P(1,:))
ylabel('Temp Bearing'); xlabel('Sample');
legend('Real Value', 'Estimated Value');
title(' Neural network test using the training set');

figure(4)
histogram(T(1,:)-P(1,:))
ylabel('Frecuency'); xlabel('Samples');
title(' Histogram of error with training data');
dt_anillosgen=std(T-P);
media_anillosgen=mean(T-P);
error_cuadratico_anillosgen=mse(T-P);

```

-Ángulo del paso de pala:

```
clear all  
close all
```

```
load('filtrado2010_angulo_palas.mat');  
load('filtrado2010_vel_viento.mat');  
load('filtrado2010_pot_total.mat');  
load('filtrado2010_angulo_viento.mat');
```

```
%[nsamples m]=size(data);
```

```
[nsamples m]=size(filtrado2010_angulo_palas);  
t=1:nsamples;
```

```
%plot(t, data(:,1), t, data(:,2), t, data(:,3))
```

```
figure(1)  
plot(t, filtrado2010_angulo_palas,t, filtrado2010_vel_viento,t,  
filtrado2010_pot_total,t, filtrado2010_angulo_viento)  
ylabel('Magnitude'); xlabel('Sample');  
legend('angulo_palas', 'vel_viento');  
title(' Variables');
```

```
training=nsamples;  
X=zeros(training,3); %Only first training input samples  
X(:,1)=filtrado2010_vel_viento(1:training);  
X(:,2)=filtrado2010_pot_total(1:training);  
X(:,3)=filtrado2010_angulo_viento(1:training);
```

```
T=zeros(training,1); %Only first training target output samples  
T(:,1)=filtrado2010_angulo_palas(1:training,1);
```

```
%T(:,2)=data(1:june,9); %oil pressure guide vane position  
%T=data(1:june,9); %pressure guide vane position  
T=T';  
X=X';
```

```
net_pasopalas = feedforwardnet([50 47], 'trainlm');  
net_pasopalas = configure(net_pasopalas,X,T);
```

```
%Criteria for splitting the training set
```

```
net_pasopalas.divideFcn='dividerand';  
net_pasopalas.divideParam.trainRatio = 70/100;  
net_pasopalas.divideParam.valRatio = 15/100;  
net_pasopalas.divideParam.testRatio = 15/100;
```

```
% Inicialización de pesos
```

```

net_pasopalas=init(net_pasopalas);
% Se ajustan diversos parámetros del entrenamiento

net_pasopalas.trainParam.epochs = 10000;
net_pasopalas.trainParam.lr = 0.002;
net_pasopalas.trainParam.show = 50;
net_pasopalas.trainParam.goal = 1e-5;
net_pasopalas.trainParam.max_fail =60; % Failures allowed in
validation

[net_pasopalas, traza] = train(net_pasopalas,X,T);
%view(net)
Yp = net_pasopalas(X);
perf = perform(net_pasopalas,Yp,X);

% Training error representation
figure(2)
plot(traza.epoch, traza.perf, traza.epoch, traza.vperf, traza.epoch,
traza.tperf);
legend('training', 'Validation', 'Test');
ylabel('Cuadratic Error');
xlabel('Epoch');

% Prediction of the NN with training set

P = sim(net_pasopalas,X);

% Representation predicted and real values in the output

figure(3);
%plot(X,T, 'sr',X,Z,'X')
plot(1:training, T(1,:),1:training,P(1,:))
ylabel('Angle'); xlabel('Sample');
legend('Real Value', 'Estimated Value');
title(' Neural network test using the training set');

figure(4)
histogram(T(1,:)-P(1,:))
ylabel('Frecuency'); xlabel('Samples');
title(' Histogram of error with training data');
dt_pasopalas=std(T-P);
media_pasopalas=mean(T-P);
error_cuadratico_pasopalas=mse(T-P);

```

-Rodamiento DE del generador

```
clear all  
close all
```

```
load('filtrado2010_tem_rod_DE_gen.mat');  
load('filtrado2010_tem_interior_nac.mat');  
load('filtrado2010_pot_total.mat');  
load('filtrado2010_vel_viento.mat');
```

```
%[nsamples m]=size(data);
```

```
[nsamples m]=size(filtrado2010_tem_rod_DE_gen);  
t=1:nsamples;
```

```
%plot(t, data(:,1), t, data(:,2), t, data(:,3))
```

```
figure(1)  
plot(t, filtrado2010_tem_rod_DE_gen, t, filtrado2010_tem_interior_nac,  
t, filtrado2010_pot_total, t, filtrado2010_vel_viento)  
ylabel('Magnitude'); xlabel('Sample');  
legend('tem_rod_DE_gen', 'tem_interior_nac', 'pot_total',  
'vel_viento');  
title(' Variables');
```

```
training=nsamples;  
X=zeros(training,3); %Only first training input samples  
X(:,1)=filtrado2010_tem_interior_nac(1:training);  
X(:,2)=filtrado2010_pot_total(1:training);  
X(:,3)=filtrado2010_vel_viento(1:training);  
  
T=zeros(training,1); %Only first training target output samples  
T(:,1)=filtrado2010_tem_rod_DE_gen(1:training,1);  
  
%T(:,2)=data(1:june,9); %oil pressure guide vane position  
%T=data(1:june,9); %pressure guide vane position  
T=T';  
X=X';
```

```
net_rodgen_de = feedforwardnet([50 46], 'trainlm');  
net_rodgen_de = configure(net_rodgen_de, X, T);
```

```
%Criteria for splitting the training set
```

```
net_rodgen_de.divideFcn='dividerand';  
net_rodgen_de.divideParam.trainRatio = 70/100;  
net_rodgen_de.divideParam.valRatio = 15/100;  
net_rodgen_de.divideParam.testRatio = 15/100;
```

```
% Inicialización de pesos  
net_rodgen_de=init(net_rodgen_de);
```

% Se ajustan diversos parámetros del entrenamiento

```
net_rodgen_de.trainParam.epochs = 10000;  
net_rodgen_de.trainParam.lr = 0.002;  
net_rodgen_de.trainParam.show = 50;  
net_rodgen_de.trainParam.goal = 1e-5;  
net_rodgen_de.trainParam.max_fail = 40; % Failures allowed in  
validation
```

```
[net_rodgen_de, traza] = train(net_rodgen_de,X,T);  
%view(net)  
Yp = net_rodgen_de(X);  
perf = perform(net_rodgen_de,Yp,X);
```

% Training error representation

```
figure(2)  
plot(traza.epoch, traza.perf, traza.epoch, traza.vperf, traza.epoch,  
traza.tperf);  
legend('training', 'Validation', 'Test');  
ylabel('Cuadratic Error');  
xlabel('Epoch');
```

% Prediction of the NN with training set

```
P = sim(net_rodgen_de,X);
```

% Representation predicted and real values in the output

```
figure(3);  
%plot(X,T, 'sr',X,Z,'X')  
plot(1:training, T(1,:),1:training, P(1,:))  
ylabel('Temp Bearing'); xlabel('Sample');  
legend('Real Value', 'Estimated Value');  
title(' Neural network test using the training set');
```

```
figure(4)  
histogram(T(1,:)-P(1,:))  
ylabel('Frecuency'); xlabel('Samples');  
title(' Histogram of error with training data');  
dt_rodgen_de=std(T-P);  
media_rodgen_de=mean(T-P);  
error_cuadratico_rodgen_de=mse(T-P);
```

-Rodamiento NDE del generador

```
clear all  
close all
```

```
load('filtrado2010_tem_rod_NDE_gen.mat');  
load('filtrado2010_tem_interior_nac.mat');  
load('filtrado2010_pot_total.mat');  
load('filtrado2010_vel_viento.mat');
```

```
%[nsamples m]=size(data);
```

```
[nsamples m]=size(filtrado2010_tem_rod_NDE_gen);  
t=1:nsamples;
```

```
%plot(t, data(:,1), t, data(:,2), t, data(:,3))
```

```
figure(1)  
plot(t, filtrado2010_tem_rod_NDE_gen, t,  
filtrado2010_tem_interior_nac, t, filtrado2010_pot_total, t,  
filtrado2010_vel_viento)  
ylabel('Magnitude'); xlabel('Sample');  
legend('tem_rod_NDE_gen', 'tem_interior_nac', 'pot_total',  
'vel_viento');  
title(' Variables');
```

```
training=nsamples;  
X=zeros(training,3); %Only first training input samples  
X(:,1)=filtrado2010_tem_interior_nac(1:training);  
X(:,2)=filtrado2010_pot_total(1:training);  
X(:,3)=filtrado2010_vel_viento(1:training);  
  
T=zeros(training,1); %Only first training target output samples  
T(:,1)=filtrado2010_tem_rod_NDE_gen(1:training,1); %temperature in the  
bearing DE  
  
%T(:,2)=data(1:june,9); %oil pressure guide vane position  
%T=data(1:june,9); %pressure guide vane position  
T=T';  
X=X';
```

```
net_rodgen_nde = feedforwardnet([50 45], 'trainlm');  
net_rodgen_nde = configure(net_rodgen_nde, X, T);
```

```
%Criteria for splitting the training set
```

```
net_rodgen_nde.divideFcn='dividerand';  
net_rodgen_nde.divideParam.trainRatio = 70/100;  
net_rodgen_nde.divideParam.valRatio = 15/100;  
net_rodgen_nde.divideParam.testRatio = 15/100;
```

```

% Inicialización de pesos
net_rodgen_nde=init(net_rodgen_nde);
% Se ajustan diversos parámetros del entrenamiento

net_rodgen_nde.trainParam.epochs = 10000;
net_rodgen_nde.trainParam.lr = 0.002;
net_rodgen_nde.trainParam.show = 50;
net_rodgen_nde.trainParam.goal = 1e-5;
net_rodgen_nde.trainParam.max_fail =40; % Failures allowed in
validation

[net_rodgen_nde, traza] = train(net_rodgen_nde,X,T);
%view(net)
Yp = net_rodgen_nde(X);
perf = perform(net_rodgen_nde,Yp,X);

% Training error representation
figure(2)
plot(traza.epoch, traza.perf, traza.epoch, traza.vperf, traza.epoch,
traza.tperf);
legend('training', 'Validation', 'Test');
ylabel('Cuadratic Error');
xlabel('Epoch');

% Prediction of the NN with training set

P = sim(net_rodgen_nde,X);

% Representation predicted and real values in the output

figure(3);
%plot(X,T, 'sr',X,Z,'X')
plot(1:training, T(1,:),1:training, P(1,:))
ylabel('Temp Bearing'); xlabel('Sample');
legend('Real Value', 'Estimated Value');
title(' Neural network test using the training set');

figure(4)
histogram(T(1,:)-P(1,:))
ylabel('Frecuency'); xlabel('Samples');
title(' Histogram of error with training data');
dt_rodgen_nde=std(T-P);
media_rodgen_nde=mean(T-P);
error_cuadratico_rodgen_nde=mse(T-P);

```

-Rodamiento de la multiplicadora:

```
clear all  
close all  
clc
```

```
load('filtrado2010_tem_rod_alta_multi.mat');  
load('filtrado2010_tem_interior_nac.mat');  
load('filtrado2010_pot_total.mat');  
load('filtrado2010_vel_viento.mat');
```

```
%[nsamples m]=size(data);
```

```
[nsamples m]=size(filtrado2010_tem_rod_alta_multi);  
t=1:nsamples;
```

```
%plot(t, data(:,1), t, data(:,2), t, data(:,3))
```

```
figure(1)  
plot(t, filtrado2010_tem_rod_alta_multi, t,  
filtrado2010_tem_interior_nac, t, filtrado2010_pot_total, t,  
filtrado2010_vel_viento)  
ylabel('Magnitude'); xlabel('Sample');  
legend('tem_rod_alta_multi', 'tem_interior_nac', 'pot_total',  
'vel_viento');  
title(' Variables');
```

```
training=nsamples;  
X=zeros(training,3);  
X(:,1)=filtrado2010_tem_interior_nac(1:training);  
X(:,2)=filtrado2010_pot_total(1:training);  
X(:,3)=filtrado2010_vel_viento(1:training);
```

```
T=zeros(training,1); %Only first training target output samples  
T(:,1)=filtrado2010_tem_rod_alta_multi(1:training,1); %temperature in  
the bearing DE
```

```
%T(:,2)=data(1:june,9); %oil pressure guide vane position  
%T=data(1:june,9); %pressure guide vane position  
T=T';  
X=X';
```

```
net_rodmulti = feedforwardnet([50 45], 'trainlm');  
net_rodmulti = configure(net_rodmulti, X, T);
```

```
%Criteria for splitting the training set
```

```
net_rodmulti.divideFcn='dividerand';  
net_rodmulti.divideParam.trainRatio = 75/100;  
net_rodmulti.divideParam.valRatio = 15/100;  
net_rodmulti.divideParam.testRatio = 15/100;
```

```

% Inicialización de pesos
net_rodmulti=init(net_rodmulti);
% Se ajustan diversos parámetros del entrenamiento

net_rodmulti.trainParam.epochs = 10000;
net_rodmulti.trainParam.lr = 0.00002;
net_rodmulti.trainParam.show = 50;
net_rodmulti.trainParam.goal = 1e-5;
net_rodmulti.trainParam.max_fail =80; % Failures allowed in
validation

[net_rodmulti, traza] = train(net_rodmulti,X,T);
%view(net)
Yp = net_rodmulti(X);
perf = perform(net_rodmulti,Yp,X);

% Training error representation
figure(2)
plot(traza.epoch, traza.perf, traza.epoch, traza.vperf, traza.epoch,
traza.tperf);
legend('training', 'Validation', 'Test');
ylabel('Cuadratic Error');
xlabel('Epoch');

% Prediction of the NN with training set

P = sim(net_rodmulti,X);

% Representation predicted and real values in the output

figure(3);
%plot(X,T, 'sr',X,Z,'X')
plot(1:training, T(1,:),1:training, P(1,:))
ylabel('Temp Bearing'); xlabel('Sample');
legend('Real Value', 'Estimated Value');
title(' Neural network test using the training set');

figure(4)
histogram(T(1,:)-P(1,:))
ylabel('Frecuency'); xlabel('Samples');
title(' Histogram of error with training data');
dt_rodmulti=std(T-P);
media_rodmulti=mean(T-P);
error_cuadratico_rodmulti=mse(T-P);

```

Anexo V – Códigos para la creación de modelos de comportamiento normal basados en las redes neuronales RBF

-Aceite de la multiplicadora:

```
clear all
close all
clc
```

```
load('filtrado2010_tem_aceite_multi.mat');
load('filtrado2010_tem_interior_nac.mat');
load('filtrado2010_pot_total.mat');
load('filtrado2010_vel_viento.mat');
```

```
%[nsamples m]=size(data);
```

```
[nsamples m]=size(filtrado2010_tem_aceite_multi);
t=1:nsamples;
```

```
%plot(t, data(:,1), t, data(:,2), t, data(:,3))
```

```
figure(1)
plot(t, filtrado2010_tem_aceite_multi, t,
filtrado2010_tem_interior_nac, t, filtrado2010_pot_total, t,
filtrado2010_vel_viento)
ylabel('Magnitude'); xlabel('Sample');
legend('tem_aceite_multi', 'tem_interior_nac', 'pot_total',
'vel_viento');
title(' Variables');
```

```
training=nsamples;
X=zeros(training,3); %Only first training input samples
X(:,1)=filtrado2010_tem_interior_nac(1:training);
X(:,2)=filtrado2010_pot_total(1:training);
X(:,3)=filtrado2010_vel_viento(1:training);
```

```
T=zeros(training,1); %Only first training target output samples
T(:,1)=filtrado2010_tem_aceite_multi(1:training,1);
```

```
%T(:,2)=data(1:june,9); %oil pressure guide vane position
%T=data(1:june,9); %pressure guide vane position
T=T';
X=X';
```

```
net_aceite_multi = newgrnn(X,T);
```

```
% Prediction of the NN with training set
```

```
P = sim(net_aceite_multi,X);
```

% Representation predicted and real values in the output

```
figure(3);  
%plot(X,T, 'sr',X,Z,'X')  
plot(1:training, T(1,:),1:training, P(1,:))  
ylabel('Temp Bearing'); xlabel('Sample');  
legend('Real Value', 'Estimated Value');  
title(' Neural network test using the training set');
```

```
figure(4)  
histogram(T(1,:)-P(1,:))  
ylabel('Frecuency'); xlabel('Samples');  
title(' Histogram of error with training data');  
dt_aceite_multi=std(T-P);  
media_aceite_multi=mean(T-P);  
error_cuadratico_aceite_multi=mse(T-P);
```

-Anillos del generador:

```
clear all  
close all  
clc
```

```
load('filtrado2010_tem_anillos_sld_gen.mat');  
load('filtrado2010_tem_interior_nac.mat');  
load('filtrado2010_pot_total.mat');  
load('filtrado2010_vel_viento.mat');
```

%[nsamples m]=size(data);

```
[nsamples m]=size(filtrado2010_tem_anillos_sld_gen);  
t=1:nsamples;
```

%plot(t, data(:,1), t, data(:,2), t, data(:,3))

```
figure(1)  
plot(t, filtrado2010_tem_anillos_sld_gen, t,  
filtrado2010_tem_interior_nac, t, filtrado2010_pot_total, t,  
filtrado2010_vel_viento)  
ylabel('Magnitude'); xlabel('Sample');  
legend('tem_anillos_sld_gen', 'tem_interior_nac', 'pot_total',  
'vel_viento');  
title(' Variables');
```

```
training=nsamples;  
X=zeros(training,3); %Only first training input samples  
X(:,1)=filtrado2010_tem_interior_nac(1:training);  
X(:,2)=filtrado2010_pot_total(1:training);  
X(:,3)=filtrado2010_vel_viento(1:training);
```

T=zeros(training,1); %Only first training target output samples

```

T(:,1)=filtrado2010_tem_anillos_sld_gen(1:training,1);

%T(:,2)=data(1:june,9); %oil pressure guide vane position
%T=data(1:june,9); %pressure guide vane position
T=T';
X=X';

net_anillosgen = newgrnn(X,T);

% Prediction of the NN with training set

P = sim(net_anillosgen,X);

% Representation predicted and real values in the output

figure(3);
%plot(X,T, 'sr',X,Z,'X')
plot(1:training, T(1,:),1:training, P(1,:))
ylabel('Temp Bearing'); xlabel('Sample');
legend('Real Value', 'Estimated Value');
title(' Neural network test using the training set');

figure(4)
histogram(T(1,:)-P(1,:))
ylabel('Frecuency'); xlabel('Samples');
title(' Histogram of error with training data');
dt_anillosgen=std(T-P);
media_anillosgen=mean(T-P);
error_cuadratico_anillosgen=mse(T-P);

-Ángulo del paso de pala:
clear all
close all
clc

load('filtrado2010_angulo_palas.mat');
load('filtrado2010_vel_viento.mat');
load('filtrado2010_pot_total.mat');
load('filtrado2010_angulo_viento.mat');

%[nsamples m]=size(data);

[nsamples m]=size(filtrado2010_angulo_palas);
t=1:nsamples;

%plot(t, data(:,1), t, data(:,2), t, data(:,3))

figure(1)
plot(t, filtrado2010_angulo_palas,t, filtrado2010_vel_viento,t,
filtrado2010_pot_total,t, filtrado2010_angulo_viento)

```

```

ylabel('Magnitude'); xlabel('Sample');
legend('angulo_palas', 'vel_viento');
title(' Variables');

training=nsamples;
X=zeros(training,3); %Only first training input samples
X(:,1)=filtrado2010_vel_viento(1:training);
X(:,2)=filtrado2010_pot_total(1:training);
X(:,3)=filtrado2010_angulo_viento(1:training);

T=zeros(training,1); %Only first training target output samples
T(:,1)=filtrado2010_angulo_palas(1:training,1);

%T(:,2)=data(1:june,9); %oil pressure guide vane position
%T=data(1:june,9); %pressure guide vane position
T=T';
X=X';

net_pasopalas = newgrnn(X,T);
% Prediction of the NN with training set

P = sim(net_pasopalas,X);

% Representation predicted and real values in the output

figure(3);
%plot(X,T, 'sr',X,Z, 'X')
plot(1:training, T(1,:),1:training, P(1,:))
ylabel('Temp Bearing'); xlabel('Sample');
legend('Real Value', 'Estimated Value');
title(' Neural network test using the training set');

figure(4)
histogram(T(1,:)-P(1,:))
ylabel('Frecuency'); xlabel('Samples');
title(' Histogram of error with training data');
dt_pasopalas=std(T-P);
media_pasopalas=mean(T-P);
error_cuadratico_pasopalas=mse(T-P);

-Rodamiento DE del generador
clear all
close all
clc

load('filtrado2010_tem_rod_DE_gen.mat');
load('filtrado2010_tem_interior_nac.mat');
load('filtrado2010_pot_total.mat');
load('filtrado2010_vel_viento.mat');

%[nsamples m]=size(data);

```

```

[nsamples m]=size(filtrado2010_tem_rod_DE_gen);
t=1:nsamples;

%plot(t, data(:,1), t, data(:,2), t, data(:,3))

figure(1)
plot(t, filtrado2010_tem_rod_DE_gen, t, filtrado2010_tem_interior_nac,
t, filtrado2010_pot_total, t, filtrado2010_vel_viento)
ylabel('Magnitude'); xlabel('Sample');
legend('tem_rod_DE_gen', 'tem_interior_nac', 'pot_total',
'vel_viento');
title(' Variables');

training=nsamples;
X=zeros(training,3); %Only first training input samples
X(:,1)=filtrado2010_tem_interior_nac(1:training);
X(:,2)=filtrado2010_pot_total(1:training);
X(:,3)=filtrado2010_vel_viento(1:training);

T=zeros(training,1); %Only first training target output samples
T(:,1)=filtrado2010_tem_rod_DE_gen(1:training,1);

%T(:,2)=data(1:june,9); %oil pressure guide vane position
%T=data(1:june,9); %pressure guide vane position
T=T';
X=X';

net_rodgen_de = newgrnn(X,T);

% Prediction of the NN with training set

P = sim(net_rodgen_de,X);

% Representation predicted and real values in the output

figure(3);
%plot(X,T, 'sr',X,Z, 'X')
plot(1:training, T(1,:),1:training, P(1,:)+1)
ylabel('Temp Bearing'); xlabel('Sample');
legend('Real Value', 'Estimated Value');
title(' Neural network test using the training set');

figure(4)
histogram(T(1,:)-P(1,:))
ylabel('Frecuency'); xlabel('Samples');
title(' Histogram of error with training data');
dt_rodgen_de=std(T-P);
media_rodgen_de=mean(T-P);
error_cuadratico_rodgen_de=mse(T-P);

```

-Rodamiento NDE del generador

```
clear all
close all
clc
```

```
load('filtrado2010_tem_rod_NDE_gen.mat');
load('filtrado2010_tem_interior_nac.mat');
load('filtrado2010_pot_total.mat');
load('filtrado2010_vel_viento.mat');
```

```
%[nsamples m]=size(data);
```

```
[nsamples m]=size(filtrado2010_tem_rod_NDE_gen);
t=1:nsamples;
```

```
%plot(t, data(:,1), t, data(:,2), t, data(:,3))
```

```
figure(1)
plot(t, filtrado2010_tem_rod_NDE_gen, t,
filtrado2010_tem_interior_nac, t, filtrado2010_pot_total, t,
filtrado2010_vel_viento)
ylabel('Magnitude'); xlabel('Sample');
legend('tem_rod_NDE_gen', 'tem_interior_nac', 'pot_total',
'vel_viento');
title(' Variables');
```

```
training=nsamples;
X=zeros(training,3); %Only first training input samples
X(:,1)=filtrado2010_tem_interior_nac(1:training);
X(:,2)=filtrado2010_pot_total(1:training);
X(:,3)=filtrado2010_vel_viento(1:training);

T=zeros(training,1); %Only first training target output samples
T(:,1)=filtrado2010_tem_rod_NDE_gen(1:training,1);

%T(:,2)=data(1:june,9); %oil pressure guide vane position
%T=data(1:june,9); %pressure guide vane position
T=T';
X=X';
```

```
net_rodgen_nde = newgrnn(X,T);
```

```
% Prediction of the NN with training set
```

```
P = sim(net_rodgen_nde,X);
```

```
% Representation predicted and real values in the output
```

```
figure(3);
%plot(X,T, 'sr',X,Z,'X')
plot(1:training, T(1,:),1:training, P(1,:))
```

```
ylabel('Temp Bearing'); xlabel('Sample');
legend('Real Value', 'Estimated Value');
title(' Neural network test using the training set');
```

```
figure(4)
histogram(T(1,:)-P(1,:))
ylabel('Frecuency'); xlabel('Samples');
title(' Histogram of error with training data');
dt_rodgen_nde=std(T-P);
media_rodgen_nde=mean(T-P);
error_cuadratico_rodgen_nde=mse(T-P);
```

-Rodamiento de la multiplicadora:

```
clear all
close all
clc
```

```
load('filtrado2010_tem_rod_alta_multi.mat');
load('filtrado2010_tem_interior_nac.mat');
load('filtrado2010_pot_total.mat');
load('filtrado2010_vel_viento.mat');
```

```
%[nsamples m]=size(data);
```

```
[nsamples m]=size(filtrado2010_tem_rod_alta_multi);
t=1:nsamples;
```

```
%plot(t, data(:,1), t, data(:,2), t, data(:,3))
```

```
figure(1)
plot(t, filtrado2010_tem_rod_alta_multi, t,
filtrado2010_tem_interior_nac, t, filtrado2010_pot_total, t,
filtrado2010_vel_viento)
ylabel('Magnitude'); xlabel('Sample');
legend('tem_rod_alta_multi', 'tem_interior_nac', 'pot_total',
'vel_viento');
title(' Variables');
```

```
training=nsamples;
X=zeros(training,3); %Only first training input samples
X(:,1)=filtrado2010_tem_interior_nac(1:training);
X(:,2)=filtrado2010_pot_total(1:training);
X(:,3)=filtrado2010_vel_viento(1:training);
```

```
T=zeros(training,1); %Only first training target output samples
T(:,1)=filtrado2010_tem_rod_alta_multi(1:training,1);
```

```
%T(:,2)=data(1:june,9); %oil pressure guide vane position
%T=data(1:june,9); %pressure guide vane position
T=T';
X=X';
```

```

net_rodmulti = newgrnn(X,T);

% net_rodmulti = configure(net_rodmulti,X,T);

% Inicialización de pesos
%net_rodmulti=init(net_rodmulti);
% Se ajustan diversos parámetros del entrenamiento

%[net_rodmulti, traza] = train(net_rodmulti,X,T);

% Prediction of the NN with training set

P = sim(net_rodmulti,X);

% Representation predicted and real values in the output

figure(3);
%plot(X,T, 'sr',X,Z,'X')
plot(1:training, T(1,:),1:training, P(1,:))
ylabel('Temp Bearing'); xlabel('Sample');
legend('Real Value', 'Estimated Value');
title(' Neural network test using the training set');

figure(4)
histogram(T(1,:)-P(1,:))
ylabel('Frecuency'); xlabel('Samples');
title(' Histogram of error with training data');

dt_rodmulti=std(T-P);
media_rodmulti=mean(T-P);
error_cuadratico_rodmulti=mse(T-P);

```

Anexo VI – Códigos para la creación de modelos de comportamiento normal basados en las redes neuronales RBF

-Aceite de la multiplicadora:

```
clear all
close all
clc
```

```
load('filtrado2010_tem_aceite_multi.mat');
load('filtrado2010_tem_interior_nac.mat');
load('filtrado2010_pot_total.mat');
load('filtrado2010_vel_viento.mat');
```

```
%[nsamples m]=size(data);
```

```
[nsamples m]=size(filtrado2010_tem_aceite_multi);
t=1:nsamples;
```

```
%plot(t, data(:,1), t, data(:,2), t, data(:,3))
```

```
figure(1)
plot(t, filtrado2010_tem_aceite_multi, t,
filtrado2010_tem_interior_nac, t, filtrado2010_pot_total, t,
filtrado2010_vel_viento)
ylabel('Magnitude'); xlabel('Sample');
legend('tem_aceite_multi', 'tem_interior_nac', 'pot_total',
'vel_viento');
title(' Variables');
```

```
training=nsamples;
X=zeros(training,3); %Only first training input samples
X(:,1)=filtrado2010_tem_interior_nac(1:training);
X(:,2)=filtrado2010_pot_total(1:training);
X(:,3)=filtrado2010_vel_viento(1:training);
```

```
T=zeros(training,1); %Only first training target output samples
T(:,1)=filtrado2010_tem_aceite_multi(1:training,1);
```

```
%T(:,2)=data(1:june,9); %oil pressure guide vane position
%T=data(1:june,9); %pressure guide vane position
% T=T';
% X=X';
```

```
model_svm_aceite_multi=fitrsvm(X,T, 'Standardize', true,
'KernelFunction','polynomial',...
'KernelScale','auto', 'Solver','SMO'); % kernel es una gaussiana.
```

```
% Prediction of the NN with training set
```

```
P = predict(model_svm_aceite_multi,X);
```

```
% Representation predicted and real values in the output
```

```
figure(3);  
%plot(X,T, 'sr',X,Z,'X')  
plot(1:training, T(:,1),1:training, P(:,1))  
ylabel('Temp Bearing'); xlabel('Sample');  
legend('Real Value', 'Estimated Value');  
title(' Neural network test using the training set');
```

```
figure(4)  
histogram(T(:,1)-P(:,1))  
ylabel('Frecuency'); xlabel('Samples');  
title(' Histogram of error with training data');  
dt_aceite_multi=std(T-P);  
media_aceite_multi=mean(T-P);  
error_cuadratico_aceite_multi=mse(T-P);
```

-Anillos del generador:

```
clear all  
close all  
clc
```

```
load('filtrado2010_tem_anillos_sld_gen.mat');  
load('filtrado2010_tem_interior_nac.mat');  
load('filtrado2010_pot_total.mat');  
load('filtrado2010_vel_viento.mat');
```

```
%[nsamples m]=size(data);
```

```
[nsamples m]=size(filtrado2010_tem_anillos_sld_gen);  
t=1:nsamples;
```

```
%plot(t, data(:,1), t, data(:,2), t, data(:,3))
```

```
figure(1)  
plot(t, filtrado2010_tem_anillos_sld_gen, t,  
filtrado2010_tem_interior_nac, t, filtrado2010_pot_total, t,  
filtrado2010_vel_viento)  
ylabel('Magnitude'); xlabel('Sample');  
legend('tem_anillos_sld_gen', 'tem_interior_nac', 'pot_total',  
'vel_viento');  
title(' Variables');
```

```
training=nsamples;  
X=zeros(training,3); %Only first training input samples  
X(:,1)=filtrado2010_tem_interior_nac(1:training);  
X(:,2)=filtrado2010_pot_total(1:training);  
X(:,3)=filtrado2010_vel_viento(1:training);
```

```
T=zeros(training,1); %Only first training target output samples
T(:,1)=filtrado2010_tem_anillos_sld_gen(1:training);
```

```
%T(:,2)=data(1:june,9); %oil pressure guide vane position
%T=data(1:june,9); %pressure guide vane position
% T=T';
% X=X';
```

```
model_svm_anillosgen=fitrsvm(X,T, 'Standardize', true,
'KernelFunction','polynomial',...
'KernelScale','auto', 'Solver','SMO'); % kernel es una gaussiana.
```

```
% Prediction of the NN with training set
```

```
P = predict(model_svm_anillosgen,X);
```

```
% Representation predicted and real values in the output
```

```
figure(3);
%plot(X,T, 'sr',X,Z,'X')
plot(1:training, T(:,1),1:training, P(:,1))
ylabel('Temp Bearing'); xlabel('Sample');
legend('Real Value', 'Estimated Value');
title(' Neural network test using the training set');
```

```
figure(4)
histogram(T(:,1)-P(:,1))
ylabel('Frecuency'); xlabel('Samples');
title(' Histogram of error with training data');
dt_anillosgen=std(T-P);
media_anillosgen=mean(T-P);
error_cuadratico_anillosgen=mse(T-P);
```

-Ángulo del paso de pala:

```
clear all
close all
clc
```

```
load('filtrado2010_angulo_palas.mat');
load('filtrado2010_vel_viento.mat');
load('filtrado2010_pot_total.mat');
load('filtrado2010_angulo_viento.mat');
```

```
%[nsamples m]=size(data);
```

```
[nsamples m]=size(filtrado2010_angulo_palas);
t=1:nsamples;
```

```

%plot(t, data(:,1), t, data(:,2), t, data(:,3))

figure(1)
plot(t, filtrado2010_angulo_palas,t, filtrado2010_vel_viento,t,
filtrado2010_pot_total,t, filtrado2010_angulo_viento)
ylabel('Magnitude'); xlabel('Sample');
legend('angulo_palas', 'vel_viento');
title(' Variables');

training=nsamples;
X=zeros(training,3); %Only first training input samples
X(:,1)=filtrado2010_vel_viento(1:training);
X(:,2)=filtrado2010_pot_total(1:training);
X(:,3)=filtrado2010_angulo_viento(1:training);

T=zeros(training,1); %Only first training target output samples
T(:,1)=filtrado2010_angulo_palas(1:training,1);

%T(:,2)=data(1:june,9); %oil pressure guide vane position
%T=data(1:june,9); %pressure guide vane position
% T=T';
% X=X';

model_svm_pasopalas=fitrsvm(X,T, 'Standardize', true,
'KernelFunction','polynomial',...
'KernelScale','auto', 'Solver','SMO'); % kernel es una gaussiana.

% Prediction of the NN with training set

P = predict(model_svm_pasopalas,X);

% Representation predicted and real values in the output

figure(3);
%plot(X,T, 'sr',X,Z,'X')
plot(1:training, T(:,1),1:training, P(:,1))
ylabel('Temp Bearing'); xlabel('Sample');
legend('Real Value', 'Estimated Value');
title(' Neural network test using the training set');

figure(4)
histogram(T(:,1)-P(:,1))
ylabel('Frecuency'); xlabel('Samples');
title(' Histogram of error with training data');
dt_pasopalas=std(T-P);
media_pasopalas=mean(T-P);
error_cuadratico_pasopalas=mse(T-P);

```

-Rodamiento DE del generador

```
clear all
close all
clc
```

```
load('filtrado2010_tem_rod_DE_gen.mat');
load('filtrado2010_tem_interior_nac.mat');
load('filtrado2010_pot_total.mat');
load('filtrado2010_vel_viento.mat');
```

```
%[nsamples m]=size(data);
```

```
[nsamples m]=size(filtrado2010_tem_rod_DE_gen);
t=1:nsamples;
```

```
%plot(t, data(:,1), t, data(:,2), t, data(:,3))
```

```
figure(1)
plot(t, filtrado2010_tem_rod_DE_gen, t, filtrado2010_tem_interior_nac,
t, filtrado2010_pot_total, t, filtrado2010_vel_viento)
ylabel('Magnitude'); xlabel('Sample');
legend('tem_rod_DE_gen', 'tem_interior_nac', 'pot_total',
'vel_viento');
title(' Variables');
```

```
training=nsamples;
X=zeros(training,3); %Only first training input samples
X(:,1)=filtrado2010_tem_interior_nac(1:training);
X(:,2)=filtrado2010_pot_total(1:training);
X(:,3)=filtrado2010_vel_viento(1:training);

T=zeros(training,1); %Only first training target output samples
T(:,1)=filtrado2010_tem_rod_DE_gen(1:training,1);

%T(:,2)=data(1:june,9); %oil pressure guide vane position
%T=data(1:june,9); %pressure guide vane position
% T=T';
% X=X';
```

```
model_svm_rodgen_de=fitrsvm(X,T, 'Standardize', true,
'KernelFunction','polynomial',...
'KernelScale','auto', 'Solver','SMO'); % kernel es una gaussiana.
```

```
% Prediction of the NN with training set
```

```
P = predict(model_svm_rodgen_de,X);
```

```
% Representation predicted and real values in the output
```

```
figure(3);
```

```

%plot(X,T, 'sr',X,Z,'X')
plot(1:training, T(:,1),1:training, P(:,1))
ylabel('Temp Bearing'); xlabel('Sample');
legend('Real Value', 'Estimated Value');
title(' Neural network test using the training set');

```

```

figure(4)
histogram(T(:,1)-P(:,1))
ylabel('Frecuency'); xlabel('Samples');
title(' Histogram of error with training data');
dt_rodgen_de=std(T-P);
media_rodgen_de=mean(T-P);
error_cuadratico_rodgen_de=mse(T-P);

```

-Rodamiento NDE del generador

```

clear all
close all
clc

```

```

load('filtrado2010_tem_rod_NDE_gen.mat');
load('filtrado2010_tem_interior_nac.mat');
load('filtrado2010_pot_total.mat');
load('filtrado2010_vel_viento.mat');

```

```

%[nsamples m]=size(data);

```

```

[nsamples m]=size(filtrado2010_tem_rod_NDE_gen);
t=1:nsamples;

```

```

%plot(t, data(:,1), t, data(:,2), t, data(:,3))

```

```

figure(1)
plot(t, filtrado2010_tem_rod_NDE_gen, t,
filtrado2010_tem_interior_nac, t, filtrado2010_pot_total, t,
filtrado2010_vel_viento)
ylabel('Magnitude'); xlabel('Sample');
legend('tem_rod_NDE_gen', 'tem_interior_nac', 'pot_total',
'vel_viento');
title(' Variables');

```

```

training=nsamples;
X=zeros(training,3); %Only first training input samples
X(:,1)=filtrado2010_tem_interior_nac(1:training);
X(:,2)=filtrado2010_pot_total(1:training);
X(:,3)=filtrado2010_vel_viento(1:training);

T=zeros(training,1); %Only first training target output samples
T(:,1)=filtrado2010_tem_rod_NDE_gen(1:training,1);

```

```

%T(:,2)=data(1:june,9); %oil pressure guide vane position

```

```

%T=data(1:june,9); %pressure guide vane position
% T=T';
% X=X';

model_svm_rodgen_nde=fitrsvm(X,T, 'Standardize', true,
'KernelFunction','polynomial',...
'KernelScale','auto', 'Solver','SMO'); % kernel es una gaussiana.

% Prediction of the NN with training set

P = predict(model_svm_rodgen_nde,X);

% Representation predicted and real values in the output

figure(3);
%plot(X,T, 'sr',X,Z,'X')
plot(1:training, T(:,1),1:training, P(:,1))
ylabel('Temp Bearing'); xlabel('Sample');
legend('Real Value', 'Estimated Value');
title(' Neural network test using the training set');

figure(4)
histogram(T(:,1)-P(:,1))
ylabel('Frecuency'); xlabel('Samples');
title(' Histogram of error with training data');
dt_rodgen_nde=std(T-P);
media_rodgen_nde=mean(T-P);
error_cuadratico_rodgen_nde=mse(T-P);

-Rodamiento de la multiplicadora:
clear all
close all
clc

load('filtrado2010_tem_rod_alta_multi.mat');
load('filtrado2010_tem_interior_nac.mat');
load('filtrado2010_pot_total.mat');
load('filtrado2010_vel_viento.mat');

%[nsamples m]=size(data);

[nsamples m]=size(filtrado2010_tem_rod_alta_multi);
t=1:nsamples;

%plot(t, data(:,1), t, data(:,2), t, data(:,3))

figure(1)
plot(t, filtrado2010_tem_rod_alta_multi, t,
filtrado2010_tem_interior_nac, t, filtrado2010_pot_total, t,
filtrado2010_vel_viento)
ylabel('Magnitude'); xlabel('Sample');

```

```

legend('tem_rod_alta_multi', 'tem_interior_nac', 'pot_total',
'vel_viento');
title(' Variables');

training=nsamples;
X=zeros(training,3); %Only first training input samples
X(:,1)=filtrado2010_tem_interior_nac(1:training);
X(:,2)=filtrado2010_pot_total(1:training);
X(:,3)=filtrado2010_vel_viento(1:training);

T=zeros(training,1); %Only first training target output samples
T(:,1)=filtrado2010_tem_rod_alta_multi(1:training,1);

%T(:,2)=data(1:june,9); %oil pressure guide vane position
%T=data(1:june,9); %pressure guide vane position
% T=T';
% X=X';

model_svm_rodmulti=fitrsvm(X,T, 'Standardize', true,
'KernelFunction','polynomial',...
'KernelScale','auto', 'Solver','SMO'); % kernel es una gaussiana.

% Prediction of the NN with training set

P = predict(model_svm_rodmulti,X);

% Representation predicted and real values in the output

figure(3);
%plot(X,T, 'sr',X,Z,'X')
plot(1:training, T(:,1),1:training, P(:,1))
ylabel('Temp Bearing'); xlabel('Sample');
legend('Real Value', 'Estimated Value');
title(' Neural network test using the training set');

figure(4)
histogram(T(:,1)-P(:,1))
ylabel('Frecuency'); xlabel('Samples');
title(' Histogram of error with training data');
dt_rodmulti=std(T-P);
media_rodmulti=mean(T-P);
error_cuadratico_rodmulti=mse(T-P);

```

Anexo VII – Histogramas de los datos de monitorización

Modelos basados en redes neuronales perceptrón multicapa

a) Año 2011

-Aceite de la multiplicadora:




Figura 244. Año 2011. Perceptrón multicapa. Histograma del error del aceite de la multiplicadora

-Anillos del generador




Figura 245. Año 2011. Perceptrón multicapa. Histograma del error de los anillos del generador

-Paso de palas:




Figura 246. Año 2011. Perceptrón multicapa. Histograma del error del paso de las palas

-Rodamiento DE del generador




Figura 247. Año 2011. Perceptrón multicapa. Histograma del error del rodamiento DE del generador

-Rodamiento NDE del generador:




Figura 248. Año 2011. Perceptrón multicapa. Histograma del error del rodamiento NDE del generador

-Rodamiento de la multiplicadora:




Figura 249. Año 2011. Perceptrón multicapa. Histograma del error del rodamiento de la multiplicadora

b) Año 2012

-Aceite de la multiplicadora:




Figura 250. Año 2012. Perceptrón multicapa. Histograma del error del aceite de la multiplicadora

-Anillos del generador




Figura 251. Año 2012. Perceptrón multicapa. Histograma del error de los anillos del generador

-Paso de palas:




Figura 252. Año 2012. Perceptrón multicapa. Histograma del error del paso de las palas

-Rodamiento DE del generador




Figura 253. Año 2012. Perceptrón multicapa. Histograma del error del rodamiento DE del generador

-Rodamiento NDE del generador:




Figura 254. Año 2012. Perceptrón multicapa. Histograma del error del rodamiento NDE del generador

-Rodamiento de la multiplicadora:




Figura 255. Año 2012. Perceptrón multicapa. Histograma del error del rodamiento de la multiplicadora

c) Año 2013

-Aceite de la multiplicadora:




Figura 256. Año 2013. Perceptrón multicapa. Histograma del error del aceite de la multiplicadora

-Anillos del generador




Figura 257. Año 2013. Perceptrón multicapa. Histograma del error de los anillos del generador

-Paso de palas:




Figura 258. Año 2013. Perceptrón multicapa. Histograma del error del paso de las palas

-Rodamiento DE del generador




Figura 259. Año 2013. Perceptrón multicapa. Histograma del error del rodamiento DE del generador

-Rodamiento NDE del generador:




Figura 260. Año 2013. Perceptrón multicapa. Histograma del error del rodamiento NDE del generador

-Rodamiento de la multiplicadora:




Figura 261. Año 2013. Perceptrón multicapa. Histograma del error del rodamiento de la multiplicadora

d) Año 2014

-Aceite de la multiplicadora:




Figura 262. Año 2014. Perceptrón multicapa. Histograma del error del aceite de la multiplicadora

-Anillos del generador




Figura 263. Año 2014. Perceptrón multicapa. Histograma del error de los anillos del generador

-Paso de palas:




Figura 264. Año 2014. Perceptrón multicapa. Histograma del error del paso de las palas

-Rodamiento DE del generador




Figura 265. Año 2014. Perceptrón multicapa. Histograma del error del rodamiento DE del generador

-Rodamiento NDE del generador:




Figura 266. Año 2014. Perceptrón multicapa. Histograma del error del rodamiento NDE del generador

-Rodamiento de la multiplicadora:




Figura 267. Año 2014. Perceptrón multicapa. Histograma del error del rodamiento de la multiplicadora

Modelos basados en redes neuronales RBF

a) Año 2011

-Aceite de la multiplicadora:




Figura 268. Año 2011. RBF. Histograma del error del aceite de la multiplicadora

-Anillos del generador




Figura 269. Año 2011. RBF. Histograma del error de los anillos del generador

-Paso de palas:




Figura 270. Año 2011. RBF. Histograma del error del paso de las palas

-Rodamiento DE del generador




Figura 271. Año 2011. RBF. Histograma del error del rodamiento DE del generador

-Rodamiento NDE del generador:




Figura 272. Año 2011. RBF. Histograma del error del rodamiento NDE del generador

-Rodamiento de la multiplicadora:




Figura 273. Año 2011. RBF. Histograma del error del rodamiento de la multiplicadora

b) Año 2012

-Aceite de la multiplicadora:




Figura 274. Año 2012. RBF. Histograma del error del aceite de la multiplicadora

-Anillos del generador




Figura 275. Año 2012. RBF. Histograma del error de los anillos del generador

-Paso de palas:




Figura 276. Año 2012. RBF. Histograma del error del paso de las palas

-Rodamiento DE del generador




Figura 277. Año 2012. RBF. Histograma del error del rodamiento DE del generador

-Rodamiento NDE del generador:




Figura 278. Año 2012. RBF. Histograma del error del rodamiento NDE del generador

-Rodamiento de la multiplicadora:




Figura 279. Año 2012. RBF. Histograma del error del rodamiento de la multiplicadora

c) Año 2013

-Aceite de la multiplicadora:




Figura 280. Año 2013. RBF. Histograma del error del aceite de la multiplicadora

-Anillos del generador




Figura 281. Año 2013. RBF. Histograma del error de los anillos del generador

-Paso de palas:




Figura 282. Año 2013. RBF. Histograma del error del paso de las palas

-Rodamiento DE del generador




Figura 283. Año 2013. RBF. Histograma del error del rodamiento DE del generador

-Rodamiento NDE del generador:




Figura 284. Año 2013. Perceptrón multicapa. Histograma del error del rodamiento NDE del generador

-Rodamiento de la multiplicadora:




Figura 285. Año 2013. RBF. Histograma del error del rodamiento de la multiplicadora

d) Año 2014

-Aceite de la multiplicadora:




Figura 286. Año 2014. RBF. Histograma del error del aceite de la multiplicadora

-Anillos del generador




Figura 287. Año 2014. RBF. Histograma del error de los anillos del generador

-Paso de palas:




Figura 288. Año 2014. RBF. Histograma del error del paso de las palas

-Rodamiento DE del generador




Figura 289. Año 2014. RBF. Histograma del error del rodamiento DE del generador

-Rodamiento NDE del generador:




Figura 290. Año 2014. RBF. Histograma del error del rodamiento NDE del generador

-Rodamiento de la multiplicadora:




Figura 291. Año 2014. RBF. Histograma del error del rodamiento de la multiplicadora

Modelos basados en redes neuronales RBF

a) Año 2011

-Aceite de la multiplicadora:




Figura 292. Año 2011. SVM. Histograma del error del aceite de la multiplicadora

-Anillos del generador




Figura 293. Año 2011. SVM. Histograma del error de los anillos del generador

-Paso de palas:




Figura 294. Año 2011. SVM. Histograma del error del paso de las palas

-Rodamiento DE del generador




Figura 295. Año 2011. SVM. Histograma del error del rodamiento DE del generador

-Rodamiento NDE del generador:




Figura 296. Año 2011. SVM. Histograma del error del rodamiento NDE del generador

-Rodamiento de la multiplicadora:




Figura 297. Año 2011. SVM. Histograma del error del rodamiento de la multiplicadora

b) Año 2012

-Aceite de la multiplicadora:




Figura 298. Año 2012. SVM. Histograma del error del aceite de la multiplicadora

-Anillos del generador




Figura 299. Año 2012. SVM. Histograma del error de los anillos del generador

-Paso de palas:




Figura 300. Año 2012. SVM. Histograma del error del paso de las palas

-Rodamiento DE del generador




Figura 301. Año 2012. SVM. Histograma del error del rodamiento DE del generador

-Rodamiento NDE del generador:




Figura 302. Año 2012. SVM. Histograma del error del rodamiento NDE del generador

-Rodamiento de la multiplicadora:




Figura 303. Año 2012. SVM. Histograma del error del rodamiento de la multiplicadora

c) Año 2013

-Aceite de la multiplicadora:




Figura 304. Año 2013. SVM. Histograma del error del aceite de la multiplicadora

-Anillos del generador




Figura 305. Año 2013. SVM. Histograma del error de los anillos del generador

-Paso de palas:




Figura 306. Año 2013. SVM. Histograma del error del paso de las palas

-Rodamiento DE del generador




Figura 307. Año 2013. SVM. Histograma del error del rodamiento DE del generador

-Rodamiento NDE del generador:




Figura 308. Año 2013. SVM. Histograma del error del rodamiento NDE del generador

-Rodamiento de la multiplicadora:




Figura 309. Año 2013. SVM. Histograma del error del rodamiento de la multiplicadora

d) Año 2014

-Aceite de la multiplicadora:




Figura 310. Año 2014. SVM. Histograma del error del aceite de la multiplicadora

-Anillos del generador




Figura 311. Año 2014. SVM. Histograma del error de los anillos del generador

-Paso de palas:




Figura 312. Año 2014. SVM. Histograma del error del paso de las palas

-Rodamiento DE del generador




Figura 313. Año 2014. SVM. Histograma del error del rodamiento DE del generador

-Rodamiento NDE del generador:




Figura 314. Año 2014. SVM. Histograma del error del rodamiento NDE del generador

-Rodamiento de la multiplicadora:




Figura 315. Año 2014. SVM. Histograma del error del rodamiento de la multiplicadora

Anexo VIII – Códigos para la detección de anomalías

Solo se mostrarán los códigos correspondientes al año 2011 porque para realizar los de los otros años, solo habría que cambiar el muestreo.

Modelos basados en redes neuronales

-Aceite de la multiplicadora:

```
clear all
close all
clc
```

```
load('filtrado2011_tem_aceite_multi.mat');
load('filtrado2011_tem_interior_nac.mat');
load('filtrado2011_pot_total.mat');
load('filtrado2011_vel_viento.mat');
load('net_aceite_multi.mat');
load('dt_aceite_multi');
load('filtrado2011_fecha_conv');
```

```
%[nsamples m]=size(data);
```

```
[nsamples m]=size(filtrado2011_tem_aceite_multi);
t=1:nsamples;
% nsamples=3000;
```

```
%plot(t, data(:,1), t, data(:,2), t, data(:,3))
```

```
figure(1)
plot(t, filtrado2011_tem_aceite_multi, t,
filtrado2011_tem_interior_nac, t, filtrado2011_pot_total, t,
filtrado2011_vel_viento)
ylabel('Magnitude'); xlabel('Sample');
legend('tem_aceite_multi', 'tem_interior_nac', 'pot_total',
'vel_viento');
title(' Variables');
Xt=zeros(nsamples,3); %Only first training samples
Xt(:,1)=filtrado2011_tem_interior_nac(1:nsamples);
Xt(:,2)=filtrado2011_pot_total(1:nsamples);
Xt(:,3)=filtrado2011_vel_viento(1:nsamples);
```

```
Tt=zeros(nsamples,1); %Only first 4000 samples
Tt(:,1)=filtrado2011_tem_aceite_multi(1:nsamples);
%Tt(:,2)=data(june+1:nsamples,9);
%Tt=data(june+1:nsamples,9);
Tt=Tt';
Xt=Xt';
```

```
Pt = sim(net_aceite_multi,Xt);
```

```
% Se representa la salida estimada por la red para las entradas dadas
y
% también lo que tendría que haber dado
```

```

figure(30);
%plot(X,T, 'sr',X,Z,'X')

plot(1:nsamples, Tt(1,:),1:nsamples, Pt(1,:),1:nsamples,
Pt(1,:)+2*dt_aceite_multi,'m', 1:nsamples, Pt(1,:)-
2*dt_aceite_multi,'m');

ylabel('Temperature %'); xlabel('Sample');
legend('Real Value', 'Estimated Value', 'Error margin');
title(' Neural network test with unknown cases');

figure(31)
histogram(Tt(1,:)-Pt(1,:))
ylabel('Frecuency'); xlabel('Samples');
title(' Histogram of error with unknown data');

dt_aceite_multi=std(Tt-Pt);
media_aceite_multi=mean(Tt-Pt);
error_cuadratico_aceite_multi=mse(Tt-Pt);

i=1;
j=1;
f(j)=0;
nf=0;
for k=1:20344
    if (Tt(i)>Pt(i)+2*dt_aceite_multi)|(Tt(i)<Pt(i)-2*dt_aceite_multi)
        detector(i)=1;
        f(j)=f(j)+1;
        nf=nf+1;
    end
    if (Tt(i)<Pt(i)+2*dt_aceite_multi)&(Tt(i)>Pt(i)-2*dt_aceite_multi)
        detector(i)=0;
        j=j+1;
        f(j)=0;
    end
    i=i+1;
end
[m n]=size(f);
i=1;
c=1;
for k=1:n
    if (f(i)>0)
        c=c+1;
    end
    i=i+1;
end

figure(32)
plot(1:nsamples, detector);

[m nsamples]=size(f);
i=1;
j=1;

for k=1:nsamples
    t=f(k);
    if (k==1)
        if (t==0)
            detector_filtrado(i)=0;

```

```

        end
        if(t>0)
            for l=1:t
                detector_filtrado(i)=0;
                i=i+1;
            end
        end
    end
    if(k>1)
        if(t==0)
            detector_filtrado(i)=0;
            i=i+1;
        end
        if(t>0)&(t<3)
            for l=1:t
                detector_filtrado(i)=0;
                i=i+1;
            end
            i=i+1;
        end
        if(t>2)
            for l=1:t
                detector_filtrado(i)=1;
            end
        end
        fecha2011_anomalias_aceite_multi(j,1)=filtrado2011_fecha_conv(k,1);
        fecha2011_anomalias_aceite_multi(j,2)=filtrado2011_fecha_conv(k,2);
        fecha2011_anomalias_aceite_multi(j,3)=filtrado2011_fecha_conv(k,3);
        fecha2011_anomalias_aceite_multi(j,4)=filtrado2011_fecha_conv(k,4);
        fecha2011_anomalias_aceite_multi(j,5)=filtrado2011_fecha_conv(k,5);
        fecha2011_anomalias_aceite_multi(j,6)=filtrado2011_fecha_conv(k,6);
        i=i+1;
        j=j+1;
    end
    i=i+1;
end
end

[nsamples m]=size(detector_filtrado);
figure(33)
plot(1:m, detector_filtrado);

figure(34)
plot(1:m,detector,1:m,detector_filtrado,'g');
legend('falsas alarmas', 'alarmas reales');

detector2011_aceite_multi=detector;
detector_filtrado2011_aceite_multi=detector_filtrado;

```

-Anillos del generador

```
clear all
close all
clc
```

```
load('filtrado2011_tem_anillos_sld_gen.mat');
load('filtrado2011_tem_interior_nac.mat');
load('filtrado2011_pot_total.mat');
load('filtrado2011_vel_viento.mat');
load('net_anillosgen.mat');
load('dt_anillosgen.mat');
load('filtrado2011_fecha_conv');
```

```
%[nsamples m]=size(data);
```

```
[nsamples m]=size(filtrado2011_tem_anillos_sld_gen);
t=1:nsamples;
% nsamples=3000;
```

```
%plot(t, data(:,1), t, data(:,2), t, data(:,3))
```

```
figure(1)
plot(t, filtrado2011_tem_anillos_sld_gen, t,
filtrado2011_tem_interior_nac, t, filtrado2011_pot_total, t,
filtrado2011_vel_viento)
ylabel('Magnitude'); xlabel('Sample');
legend('tem_aceite_multi', 'tem_interior_nac', 'pot_total',
'vel_viento');
title(' Variables');
Xt=zeros(nsamples,3); %Only first training samples
Xt(:,1)=filtrado2011_tem_interior_nac(1:nsamples);
Xt(:,2)=filtrado2011_pot_total(1:nsamples);
Xt(:,3)=filtrado2011_vel_viento(1:nsamples);
```

```
Tt=zeros(nsamples,1); %Only first 4000 samples
Tt(:,1)=filtrado2011_tem_anillos_sld_gen(1:nsamples);
%Tt(:,2)=data(june+1:nsamples,9);
%Tt=data(june+1:nsamples,9);
Tt=Tt';
Xt=Xt';
```

```
Pt = sim(net_anillosgen,Xt);
```

```
% Se representa la salida estimada por la red para las entradas dadas
y
% también lo que tendría que haber dado
```

```
figure(30);
%plot(X,T, 'sr',X,Z, 'X')
```

```
plot(1:nsamples, Tt(1,:),1:nsamples, Pt(1,:),1:nsamples,
Pt(1,:)+2*dt_anillosgen,'m', 1:nsamples, Pt(1,:)-2*dt_anillosgen,'m');
```

```

ylabel('Temperature %'); xlabel('Sample');
legend('Real Value', 'Estimated Value', 'Error margin')
title(' Neural network test with unknown cases');

```

```

figure(31)
histogram(Tt(1,:)-Pt(1,:))
ylabel('Frecuency'); xlabel('Samples');
title(' Histogram of error with unknown data');

```

```

dt_anillosgen=std(Tt-Pt);
media_anillosgen=mean(Tt-Pt);
error_cuadratico_anillosgen=mse(Tt-Pt);

```

```

i=1;
j=1;
f(j)=0;
nf=0;
for k=1:20344
    if (Tt(i)>Pt(i)+2*dt_anillosgen)|(Tt(i)<Pt(i)-2*dt_anillosgen)
        detector(i)=1;
        f(j)=f(j)+1;
        nf=nf+1;
    end
    if (Tt(i)<Pt(i)+2*dt_anillosgen)&(Tt(i)>Pt(i)-2*dt_anillosgen)
        detector(i)=0;
        j=j+1;
        f(j)=0;
    end
    i=i+1;
end
[m n]=size(f);
i=1;
c=1;
for k=1:n
    if (f(i)>0)
        c=c+1;
    end
    i=i+1;
end

```

```

figure(32)
plot(1:nsamples, detector);

```

```

[m nsamples]=size(f);
i=1;
j=1;
for k=1:nsamples
    t=f(k);
    if (k==1)
        if (t==0)
            detector_filtrado(i)=0;
        end
        if (t>0)
            for l=1:t
                detector_filtrado(i)=0;
                i=i+1;
            end
        end
    end
end

```

```

    if(k>1)
        if(t==0)
            detector_filtrado(i)=0;
            i=i+1;
        end
        if(t>0)&(t<3)
            for l=1:t
                detector_filtrado(i)=0;
                i=i+1;
            end
            i=i+1;
        end
        if(t>2)
            for l=1:t
                detector_filtrado(i)=1;
            end
        end
        fecha2011_anomalias_anillosgen(j,1)=filtrado2011_fecha_conv(k,1);
        fecha2011_anomalias_anillosgen(j,2)=filtrado2011_fecha_conv(k,2);
        fecha2011_anomalias_anillosgen(j,3)=filtrado2011_fecha_conv(k,3);
        fecha2011_anomalias_anillosgen(j,4)=filtrado2011_fecha_conv(k,4);
        fecha2011_anomalias_anillosgen(j,5)=filtrado2011_fecha_conv(k,5);
        fecha2011_anomalias_anillosgen(j,6)=filtrado2011_fecha_conv(k,6);
        i=i+1;
        j=j+1;
    end
    i=i+1;
end
end
end
[nsamples m]=size(detector_filtrado);
figure(33)
plot(1:m, detector_filtrado);

figure(34)
plot(1:m,detector,1:m,detector_filtrado,'g');
legend('falsas alarmas', 'alarmas reales');

detector2011_anillosgen=detector;
detector_filtrado2011_anillosgen=detector_filtrado;

```

-Paso de palas:

```

clear all
close all
clc

```

```

load('filtrado2011_angulo_palas.mat');
load('filtrado2011_vel_viento.mat');
load('filtrado2011_pot_total.mat');
load('filtrado2011_angulo_viento.mat');
load('net_pasopalas.mat');
load('dt_pasopalas.mat');
load('filtrado2011_fecha_conv');

```

```

[nsamples m]=size(data);

[nsamples m]=size(filtrado2011_angulo_palas);
t=1:nsamples;
% nsamples=3000;

%plot(t, data(:,1), t, data(:,2), t, data(:,3))

figure(1)
plot(t, filtrado2011_angulo_palas, t, filtrado2011_vel_viento, t,
filtrado2011_pot_total, t, filtrado2011_angulo_viento)
ylabel('Magnitude'); xlabel('Sample');
legend('tem_aceite_multi', 'tem_interior_nac', 'pot_total',
'vel_viento');
title(' Variables');
Xt=zeros(nsamples,3); %Only first training samples
Xt(:,1)=filtrado2011_vel_viento(1:nsamples);
Xt(:,2)=filtrado2011_pot_total(1:nsamples);
Xt(:,3)=filtrado2011_angulo_viento(1:nsamples);

Tt=zeros(nsamples,1); %Only first 4000 samples
Tt(:,1)=filtrado2011_angulo_palas(1:nsamples);
%Tt(:,2)=data(june+1:nsamples,9);
%Tt=data(june+1:nsamples,9);
Tt=Tt';
Xt=Xt';

Pt = sim(net_pasopalas,Xt);

% Se representa la salida estimada por la red para las entradas dadas
y
% también lo que tendría que haber dado

figure(30);
%plot(X,T, 'sr',X,Z,'X')

plot(1:nsamples, Tt(1,:),1:nsamples, Pt(1,:),1:nsamples,
Pt(1,:)+2*dt_pasopalas,'m', 1:nsamples, Pt(1,:)-2*dt_pasopalas,'m');

ylabel('Temperature %'); xlabel('Sample');
legend('Real Value', 'Estimated Value', 'Error margin')
title(' Neural network test with unknown cases');

figure(31)
histogram(Tt(1,:)-Pt(1,:))
ylabel('Frecuency'); xlabel('Samples');
title(' Histogram of error with unknown data');

dt_pasopalas=std(Tt-Pt);
media_pasopalas=mean(Tt-Pt);
error_cuadratico_pasopalas=mse(Tt-Pt);

i=1;
j=1;
f(j)=0;
nf=0;
for k=1:20344

```

```

        if(Tt(i)>Pt(i)+2*dt_pasopalas)|(Tt(i)<Pt(i)-2*dt_pasopalas)
            detector(i)=1;
            f(j)=f(j)+1;
            nf=nf+1;
        end
        if(Tt(i)<Pt(i)+2*dt_pasopalas)&(Tt(i)>Pt(i)-2*dt_pasopalas)
            detector(i)=0;
            j=j+1;
            f(j)=0;
        end
        i=i+1;
    end
    [m n]=size(f);
    i=1;
    c=1;
    for k=1:n
        if(f(i)>0)
            c=c+1;
        end
        i=i+1;
    end

figure(32)
plot(1:nsamples, detector);

[m nsamples]=size(f);
i=1;
j=1;
for k=1:nsamples
    t=f(k);
    if(k==1)
        if(t==0)
            detector_filtrado(i)=0;
        end
        if(t>0)
            for l=1:t
                detector_filtrado(i)=0;
                i=i+1;
            end
        end
    end
    if(k>1)
        if(t==0)
            detector_filtrado(i)=0;
            i=i+1;
        end
        if(t>0)&(t<3)
            for l=1:t
                detector_filtrado(i)=0;
                i=i+1;
            end
            i=i+1;
        end
        if(t>2)
            for l=1:t
                detector_filtrado(i)=1;
            end
        end
    end
end

fecha2011_anomalias_pasopalas(j,1)=filtrado2011_fecha_conv(k,1);
fecha2011_anomalias_pasopalas(j,2)=filtrado2011_fecha_conv(k,2);

```

```

fecha2011_anomalias_pasopalas(j,3)=filtrado2011_fecha_conv(k,3);
fecha2011_anomalias_pasopalas(j,4)=filtrado2011_fecha_conv(k,4);
fecha2011_anomalias_pasopalas(j,5)=filtrado2011_fecha_conv(k,5);
fecha2011_anomalias_pasopalas(j,6)=filtrado2011_fecha_conv(k,6);
        i=i+1;
        j=j+1;
    end
    i=i+1;
end
end
end

```

```

[nsamples m]=size(detector_filtrado);
figure(33)
plot(1:m, detector_filtrado);

figure(34)
plot(1:m,detector,1:m,detector_filtrado,'g');
legend('falsas alarmas', 'alarmas reales');

detector2011_pasopalas=detector;
detector_filtrado2011_pasopalas=detector_filtrado;

```

-Rodamiento DE del generador

```

clear all
close all
clc

```

```

load('filtrado2011_tem_rod_DE_gen.mat');
load('filtrado2011_tem_interior_nac.mat');
load('filtrado2011_pot_total.mat');
load('filtrado2011_vel_viento.mat');
load('net_rodgen_de.mat');
load('dt_rodgen_de.mat');
load('filtrado2011_fecha_conv');

```

```

%[nsamples m]=size(data);

```

```

[nsamples m]=size(filtrado2011_tem_rod_DE_gen);
t=1:nsamples;
% nsamples=3000;

```

```

%plot(t, data(:,1), t, data(:,2), t, data(:,3))

```

```

figure(1)
plot(t, filtrado2011_tem_rod_DE_gen, t, filtrado2011_tem_interior_nac,
t, filtrado2011_pot_total, t, filtrado2011_vel_viento)
ylabel('Magnitude'); xlabel('Sample');

```

```

legend('tem_aceite_multi', 'tem_interior_nac', 'pot_total',
'vel_viento');
title(' Variables');
Xt=zeros(nsamples,3); %Only first training samples
Xt(:,1)=filtrado2011_tem_interior_nac(1:nsamples);
Xt(:,2)=filtrado2011_pot_total(1:nsamples);
Xt(:,3)=filtrado2011_vel_viento(1:nsamples);

Tt=zeros(nsamples,1); %Only first 4000 samples
Tt(:,1)=filtrado2011_tem_rod_DE_gen(1:nsamples);
%Tt(:,2)=data(june+1:nsamples,9);
%Tt=data(june+1:nsamples,9);
Tt=Tt';
Xt=Xt';

Pt = sim(net_rodgen_de,Xt);

% Se representa la salida estimada por la red para las entradas dadas
y
% también lo que tendría que haber dado

figure(30);
%plot(X,T, 'sr',X,Z, 'X')

plot(1:nsamples, Tt(1,:),1:nsamples, Pt(1,:),1:nsamples,
Pt(1,:)+2*dt_rodgen_de,'m', 1:nsamples, Pt(1,:)-2*dt_rodgen_de,'m');

ylabel('Temperature %'); xlabel('Sample');
legend('Real Value', 'Estimated Value', 'Error margin')
title(' Neural network test with unknown cases');

figure(31)
histogram(Tt(1,:)-Pt(1,:))
ylabel('Frecuency'); xlabel('Samples');
title(' Histogram of error with unknown data');

dt_rodgen_de=std(Tt-Pt);
media_rodgen_de=mean(Tt-Pt);
error_cuadratico_rodgen_de=mse(Tt-Pt);

i=1;
j=1;
f(j)=0;
nf=0;
for k=1:20344
    if(Tt(i)>Pt(i)+2*dt_rodgen_de)|(Tt(i)<Pt(i)-2*dt_rodgen_de)
        detector(i)=1;
        f(j)=f(j)+1;
        nf=nf+1;
    end
    if(Tt(i)<Pt(i)+2*dt_rodgen_de)&(Tt(i)>Pt(i)-2*dt_rodgen_de)
        detector(i)=0;
        j=j+1;
        f(j)=0;
    end
end
i=i+1;
end
[m n]=size(f);
i=1;
c=1;

```

```

for k=1:n
    if(f(i)>0)
        c=c+1;
    end
    i=i+1;
end

figure(32)
plot(1:nsamples, detector);

[m nsamples]=size(f);
i=1;
j=1;
for k=1:nsamples
    t=f(k);
    if(k==1)
        if(t==0)
            detector_filtrado(i)=0;
        end
        if(t>0)
            for l=1:t
                detector_filtrado(i)=0;
                i=i+1;
            end
        end
    end
    if(k>1)
        if(t==0)
            detector_filtrado(i)=0;
            i=i+1;
        end
        if(t>0)&(t<3)
            for l=1:t
                detector_filtrado(i)=0;
                i=i+1;
            end
            i=i+1;
        end
        if(t>2)
            for l=1:t
                detector_filtrado(i)=1;
            end
        end
    end
    fecha2011_anomalias_rodgen_de(j,1)=filtrado2011_fecha_conv(k,1);
    fecha2011_anomalias_rodgen_de(j,2)=filtrado2011_fecha_conv(k,2);
    fecha2011_anomalias_rodgen_de(j,3)=filtrado2011_fecha_conv(k,3);
    fecha2011_anomalias_rodgen_de(j,4)=filtrado2011_fecha_conv(k,4);
    fecha2011_anomalias_rodgen_de(j,5)=filtrado2011_fecha_conv(k,5);
    fecha2011_anomalias_rodgen_de(j,6)=filtrado2011_fecha_conv(k,6);
    i=i+1;
    j=j+1;
end
end
end
end
end

```

```

[nsamples m]=size(detector_filtrado);
figure(33)
plot(1:m, detector_filtrado);

figure(34)
plot(1:m,detector,1:m,detector_filtrado,'g');
legend('falsas alarmas', 'alarmas reales');

detector2011_rodgen_de=detector;
detector_filtrado2011_rodgen_de=detector_filtrado;

```

-Rodamiento NDE del generador:

```

clear all
close all
clc

```

```

load('filtrado2011_tem_rod_NDE_gen.mat');
load('filtrado2011_tem_interior_nac.mat');
load('filtrado2011_pot_total.mat');
load('filtrado2011_vel_viento.mat');
load('net_rodgen_nde.mat');
load('dt_rodgen_nde.mat');
load('filtrado2011_fecha_conv');

```

```

%[nsamples m]=size(data);

```

```

[nsamples m]=size(filtrado2011_tem_rod_NDE_gen);
t=1:nsamples;
% nsamples=3000;

```

```

%plot(t, data(:,1), t, data(:,2), t, data(:,3))

```

```

figure(1)
plot(t, filtrado2011_tem_rod_NDE_gen, t,
filtrado2011_tem_interior_nac, t, filtrado2011_pot_total, t,
filtrado2011_vel_viento)
ylabel('Magnitude'); xlabel('Sample');
legend('tem_aceite_multi', 'tem_interior_nac', 'pot_total',
'vel_viento');
title(' Variables');
Xt=zeros(nsamples,3); %Only first training samples
Xt(:,1)=filtrado2011_tem_interior_nac(1:nsamples);
Xt(:,2)=filtrado2011_pot_total(1:nsamples);
Xt(:,3)=filtrado2011_vel_viento(1:nsamples);

Tt=zeros(nsamples,1); %Only first 4000 samples
Tt(:,1)=filtrado2011_tem_rod_NDE_gen(1:nsamples);
%Tt(:,2)=data(june+1:nsamples,9);
%Tt=data(june+1:nsamples,9);
Tt=Tt';
Xt=Xt';

```

```

Pt = sim(net_rodgen_nde,Xt);

```

```
% Se representa la salida estimada por la red para las entradas dadas
y
% también lo que tendría que haber dado
```

```
figure(30);
%plot(X,T, 'sr',X,Z,'X')

plot(1:nsamples, Tt(1,:),1:nsamples, Pt(1,:),1:nsamples,
Pt(1,:)+2*dt_rodgen_nde,'m', 1:nsamples, Pt(1,:)-2*dt_rodgen_nde,'m');

ylabel('Temperature %'); xlabel('Sample');
legend('Real Value', 'Estimated Value', 'Error margin')
title(' Neural network test with unknown cases');
```

```
figure(31)
histogram(Tt(1,:)-Pt(1,:))
ylabel('Frecuency'); xlabel('Samples');
title(' Histogram of error with unknown data');
```

```
dt_rodgen_nde=std(Tt-Pt);
media_rodgen_nde=mean(Tt-Pt);
error_cuadratico_rodgen_nde=mse(Tt-Pt);
```

```
i=1;
j=1;
f(j)=0;
nf=0;
for k=1:20344
    if (Tt(i)>Pt(i)+2*dt_rodgen_nde)|(Tt(i)<Pt(i)-2*dt_rodgen_nde)
        detector(i)=1;
        f(j)=f(j)+1;
        nf=nf+1;
    end
    if (Tt(i)<Pt(i)+2*dt_rodgen_nde)&(Tt(i)>Pt(i)-2*dt_rodgen_nde)
        detector(i)=0;
        j=j+1;
        f(j)=0;
    end
    i=i+1;
end
[m n]=size(f);
i=1;
c=1;
for k=1:n
    if (f(i)>0)
        c=c+1;
    end
    i=i+1;
end
```

```
figure(32)
plot(1:nsamples, detector);
```

```
[m nsamples]=size(f);
i=1;
j=1;
for k=1:nsamples
    t=f(k);
    if (k==1)
```

```

        if(t==0)
            detector_filtrado(i)=0;
        end
        if(t>0)
            for l=1:t
                detector_filtrado(i)=0;
                i=i+1;
            end
        end
    end
end
if(k>1)
    if(t==0)
        detector_filtrado(i)=0;
        i=i+1;
    end
    if(t>0)&(t<3)
        for l=1:t
            detector_filtrado(i)=0;
            i=i+1;
        end
        i=i+1;
    end
    if(t>2)
        for l=1:t
            detector_filtrado(i)=1;
        end
    end
end
end

fecha2011_anomalias_rodgen_nde(j,1)=filtrado2011_fecha_conv(k,1);
fecha2011_anomalias_rodgen_nde(j,2)=filtrado2011_fecha_conv(k,2);
fecha2011_anomalias_rodgen_nde(j,3)=filtrado2011_fecha_conv(k,3);
fecha2011_anomalias_rodgen_nde(j,4)=filtrado2011_fecha_conv(k,4);
fecha2011_anomalias_rodgen_nde(j,5)=filtrado2011_fecha_conv(k,5);
fecha2011_anomalias_rodgen_nde(j,6)=filtrado2011_fecha_conv(k,6);
    i=i+1;
    j=j+1;
end
    i=i+1;
end
end

[nsamples m]=size(detector_filtrado);
figure(33)
plot(1:m, detector_filtrado);

figure(34)
plot(1:m,detector,1:m,detector_filtrado,'g');
legend('falsas alarmas', 'alarmas reales');

detector2011_rodgen_nde=detector;
detector_filtrado2011_rodgen_nde=detector_filtrado;

```

-Rodamiento de la multiplicadora:

```
clear all
close all
clc

load('filtrado2011_tem_rod_alta_multi.mat');
load('filtrado2011_tem_interior_nac.mat');
load('filtrado2011_pot_total.mat');
load('filtrado2011_vel_viento.mat');
load('net_rodmulti.mat');
load('dt_rodmulti.mat');
load('filtrado2011_fecha_conv');

%[nsamples m]=size(data);

[nsamples m]=size(filtrado2011_tem_rod_alta_multi);
t=1:nsamples;
% nsamples=3000;

%plot(t, data(:,1), t, data(:,2), t, data(:,3))

figure(1)
plot(t, filtrado2011_tem_rod_alta_multi, t,
filtrado2011_tem_interior_nac, t, filtrado2011_pot_total, t,
filtrado2011_vel_viento)
ylabel('Magnitude'); xlabel('Sample');
legend('tem_aceite_multi', 'tem_interior_nac', 'pot_total',
'vel_viento');
title(' Variables');
Xt=zeros(nsamples,3); %Only first training samples
Xt(:,1)=filtrado2011_tem_interior_nac(1:nsamples);
Xt(:,2)=filtrado2011_pot_total(1:nsamples);
Xt(:,3)=filtrado2011_vel_viento(1:nsamples);

Tt=zeros(nsamples,1); %Only first 4000 samples
Tt(:,1)=filtrado2011_tem_rod_alta_multi(1:nsamples);
%Tt(:,2)=data(june+1:nsamples,9);
%Tt=data(june+1:nsamples,9);
Tt=Tt';
Xt=Xt';

Pt = sim(net_rodmulti,Xt);

% Se representa la salida estimada por la red para las entradas dadas
y
% también lo que tendría que haber dado

figure(30);
%plot(X,T, 'sr',X,Z,'X')

plot(1:nsamples, Tt(1,:),1:nsamples, Pt(1,:),1:nsamples,
Pt(1,:)+2*dt_rodmulti,'m', 1:nsamples, Pt(1,:)-2*dt_rodmulti,'m');
```

```

ylabel('Temperature %'); xlabel('Sample');
legend('Real Value', 'Estimated Value', 'Error margin')
title(' Neural network test with unknown cases');

figure(31)
histogram(Tt(1,:)-Pt(1,:))
ylabel('Frecuency'); xlabel('Samples');
title(' Histogram of error with unknown data');

dt_rodmulti=std(Tt-Pt);
media_rodmulti=mean(Tt-Pt);
error_cuadratico_rodmulti=mse(Tt-Pt);

i=1;
j=1;
f(j)=0;
nf=0;
for k=1:20344
    if(Tt(i)>Pt(i)+2*dt_rodmulti)|(Tt(i)<Pt(i)-2*dt_rodmulti)
        detector(i)=1;
        f(j)=f(j)+1;
        nf=nf+1;
    end
    if(Tt(i)<Pt(i)+2*dt_rodmulti)&(Tt(i)>Pt(i)-2*dt_rodmulti)
        detector(i)=0;
        j=j+1;
        f(j)=0;
    end
    i=i+1;
end
[m n]=size(f);
i=1;
c=1;
for k=1:n
    if(f(i)>0)
        c=c+1;
    end
    i=i+1;
end

figure(32)
plot(1:nsamples, detector);

[m nsamples]=size(f);
i=1;
j=1;
for k=1:nsamples
    t=f(k);
    if(k==1)
        if(t==0)
            detector_filtrado(i)=0;
        end
        if(t>0)
            for l=1:t
                detector_filtrado(i)=0;
                i=i+1;
            end
        end
    end
    if(k>1)

```

```

        if(t==0)
            detector_filtrado(i)=0;
            i=i+1;
        end
        if(t>0)&(t<3)
            for l=1:t
                detector_filtrado(i)=0;
                i=i+1;
            end
            i=i+1;
        end
        if(t>2)
            for l=1:t
                detector_filtrado(i)=1;
            end
        end

        fecha2011_anomalias_rodmulti(j,1)=filtrado2011_fecha_conv(k,1);
        fecha2011_anomalias_rodmulti(j,2)=filtrado2011_fecha_conv(k,2);
        fecha2011_anomalias_rodmulti(j,3)=filtrado2011_fecha_conv(k,3);
        fecha2011_anomalias_rodmulti(j,4)=filtrado2011_fecha_conv(k,4);
        fecha2011_anomalias_rodmulti(j,5)=filtrado2011_fecha_conv(k,5);
        fecha2011_anomalias_rodmulti(j,6)=filtrado2011_fecha_conv(k,6);
        i=i+1;
        j=j+1;
    end
    i=i+1;
end
end

[nsamples m]=size(detector_filtrado);
figure(33)
plot(1:m, detector_filtrado);

figure(34)
plot(1:m,detector,1:m,detector_filtrado,'g');
legend('falsas alarmas', 'alarmas reales');

detector2011_rodmulti=detector;
detector_filtrado2011_rodmulti=detector_filtrado;

```

Modelos basados en SVM

-Aceite de la multiplicadora:

```
clear all
close all
clc

load('filtrado2011_tem_aceite_multi.mat');
load('filtrado2011_tem_interior_nac.mat');
load('filtrado2011_pot_total.mat');
load('filtrado2011_vel_viento.mat');
load('model_svm_aceite_multi.mat');
load('dt_aceite_multi');
load('filtrado2011_fecha_conv');

%[nsamples m]=size(data);

[nsamples m]=size(filtrado2011_tem_aceite_multi);
t=1:nsamples;
% nsamples=3000;

%plot(t, data(:,1), t, data(:,2), t, data(:,3))

figure(1)
plot(t, filtrado2011_tem_aceite_multi, t,
filtrado2011_tem_interior_nac, t, filtrado2011_pot_total, t,
filtrado2011_vel_viento)
ylabel('Magnitud'); xlabel('Sample');
legend('tem_aceite_multi', 'tem_interior_nac', 'pot_total',
'vel_viento');
title(' Variables');
Xt=zeros(nsamples,3); %Only first training samples
Xt(:,1)=filtrado2011_tem_interior_nac(1:nsamples);
Xt(:,2)=filtrado2011_pot_total(1:nsamples);
Xt(:,3)=filtrado2011_vel_viento(1:nsamples);

Tt=zeros(nsamples,1); %Only first 4000 samples
Tt(:,1)=filtrado2011_tem_aceite_multi(1:nsamples);
%Tt(:,2)=data(june+1:nsamples,9);
%Tt=data(june+1:nsamples,9);
% Tt=Tt';
% Xt=Xt';

Pt = predict(model_svm_aceite_multi,Xt);

% Se representa la salida estimada por la red para las entradas dadas
y
% también lo que tendría que haber dado

figure(30);
%plot(X,T, 'sr',X,Z,'X')
```

```

plot(1:nsamples, Tt(:,1),1:nsamples, Pt(:,1),1:nsamples,
Pt(:,1)+2*dt_aceite_multi,'m', 1:nsamples, Pt(:,1)-
2*dt_aceite_multi,'m');

ylabel('Temperature %'); xlabel('Sample');
legend('Real Value', 'Estimated Value', 'Error margin');
title(' Neural network test with unknown cases');

figure(31)
histogram(Tt(:,1)-Pt(:,1))
ylabel('Frecuency'); xlabel('Samples');
title(' Histogram of error with unknown data');

dt_aceite_multi=std(Tt-Pt);
media_aceite_multi=mean(Tt-Pt);
error_cuadratico_aceite_multi=mse(Tt-Pt);

i=1;
j=1;
f(j)=0;
nf=0;
for k=1:20344
    if(Tt(i)>Pt(i)+2*dt_aceite_multi)|(Tt(i)<Pt(i)-2*dt_aceite_multi)
        detector(i)=1;
        f(j)=f(j)+1;
        nf=nf+1;
    end
    if(Tt(i)<Pt(i)+2*dt_aceite_multi)&(Tt(i)>Pt(i)-2*dt_aceite_multi)
        detector(i)=0;
        j=j+1;
        f(j)=0;
    end
    i=i+1;
end
[m n]=size(f);
i=1;
c=1;
for k=1:n
    if(f(i)>0)
        c=c+1;
    end
    i=i+1;
end

figure(32)
plot(1:nsamples, detector);

[m nsamples]=size(f);
i=1;
j=1;

for k=1:nsamples
    t=f(k);
    if(k==1)
        if(t==0)
            detector_filtrado(i)=0;
        end
        if(t>0)
            for l=1:t
                detector_filtrado(i)=0;
            end
        end
    end
    i=i+1;
end

```

```

        i=i+1;
    end
end
end
if(k>1)
    if(t==0)
        detector_filtrado(i)=0;
        i=i+1;
    end
    if(t>0)&(t<3)
        for l=1:t
            detector_filtrado(i)=0;
            i=i+1;
        end
        i=i+1;
    end
    if(t>2)
        for l=1:t
            detector_filtrado(i)=1;
        end
    end

fecha2011_anomalias_aceite_multi(j,1)=filtrado2011_fecha_conv(k,1);
fecha2011_anomalias_aceite_multi(j,2)=filtrado2011_fecha_conv(k,2);
fecha2011_anomalias_aceite_multi(j,3)=filtrado2011_fecha_conv(k,3);
fecha2011_anomalias_aceite_multi(j,4)=filtrado2011_fecha_conv(k,4);
fecha2011_anomalias_aceite_multi(j,5)=filtrado2011_fecha_conv(k,5);
fecha2011_anomalias_aceite_multi(j,6)=filtrado2011_fecha_conv(k,6);
        i=i+1;
        j=j+1;
    end
    i=i+1;
end
end
end

[nsamples m]=size(detector_filtrado);
figure(33)
plot(1:m, detector_filtrado);

figure(34)
plot(1:m,detector,1:m,detector_filtrado,'g');
legend('falsas alarmas', 'alarmas reales');

detector2011_aceite_multi=detector;
detector_filtrado2011_aceite_multi=detector_filtrado;

-Anillos del generador

clear all
close all
clc

load('filtrado2011_tem_anillos_sld_gen.mat');
load('filtrado2011_tem_interior_nac.mat');
load('filtrado2011_pot_total.mat');

```

```

load('filtrado2011_vel_viento.mat');
load('model_svm_anillosgen.mat');
load('dt_anillosgen.mat');
load('filtrado2011_fecha_conv');

%[nsamples m]=size(data);

[nsamples m]=size(filtrado2011_tem_anillos_sld_gen);
t=1:nsamples;
% nsamples=3000;

%plot(t, data(:,1), t, data(:,2), t, data(:,3))

figure(1)
plot(t, filtrado2011_tem_anillos_sld_gen, t,
filtrado2011_tem_interior_nac, t, filtrado2011_pot_total, t,
filtrado2011_vel_viento)
ylabel('Magnitude'); xlabel('Sample');
legend('tem_aceite_multi', 'tem_interior_nac', 'pot_total',
'vel_viento');
title(' Variables');
Xt=zeros(nsamples,3); %Only first training samples
Xt(:,1)=filtrado2011_tem_interior_nac(1:nsamples);
Xt(:,2)=filtrado2011_pot_total(1:nsamples);
Xt(:,3)=filtrado2011_vel_viento(1:nsamples);

Tt=zeros(nsamples,1); %Only first 4000 samples
Tt(:,1)=filtrado2011_tem_anillos_sld_gen(1:nsamples);
%Tt(:,2)=data(june+1:nsamples,9);
%Tt=data(june+1:nsamples,9);
% Tt=Tt';
% Xt=Xt';

Pt = predict(model_svm_anillosgen,Xt);

% Se representa la salida estimada por la red para las entradas dadas
y
% también lo que tendría que haber dado

figure(30);
%plot(X,T, 'sr',X,Z,'X')

plot(1:nsamples, Tt(:,1),1:nsamples, Pt(:,1),1:nsamples,
Pt(:,1)+2*dt_anillosgen,'m', 1:nsamples, Pt(:,1)-2*dt_anillosgen,'m');

ylabel('Temperature %'); xlabel('Sample');
legend('Real Value', 'Estimated Value', 'Error margin')
title(' Neural network test with unknown cases');

figure(31)
histogram(Tt(:,1)-Pt(:,1))
ylabel('Frecuency'); xlabel('Samples');
title(' Histogram of error with unknown data');

```

```

dt_anillosgen=std(Tt-Pt);
media_anillosgen=mean(Tt-Pt);
error_cuadratico_anillosgen=mse(Tt-Pt);

i=1;
j=1;
f(j)=0;
nf=0;
for k=1:20344
    if(Tt(i)>Pt(i)+2*dt_anillosgen)|(Tt(i)<Pt(i)-2*dt_anillosgen)
        detector(i)=1;
        f(j)=f(j)+1;
        nf=nf+1;
    end
    if(Tt(i)<Pt(i)+2*dt_anillosgen)&(Tt(i)>Pt(i)-2*dt_anillosgen)
        detector(i)=0;
        j=j+1;
        f(j)=0;
    end
    i=i+1;
end
[m n]=size(f);
i=1;
c=1;
for k=1:n
    if(f(i)>0)
        c=c+1;
    end
    i=i+1;
end

figure(32)
plot(1:nsamples, detector);

[m nsamples]=size(f);
i=1;
j=1;
for k=1:nsamples
    t=f(k);
    if(k==1)
        if(t==0)
            detector_filtrado(i)=0;
        end
        if(t>0)
            for l=1:t
                detector_filtrado(i)=0;
                i=i+1;
            end
        end
    end
    if(k>1)
        if(t==0)
            detector_filtrado(i)=0;
            i=i+1;
        end
        if(t>0)&(t<3)
            for l=1:t
                detector_filtrado(i)=0;
                i=i+1;
            end
            i=i+1;
        end
    end
end

```

```

        end
        if(t>2)
            for l=1:t
                detector_filtrado(i)=1;

fecha2011_anomalias_anillosgen(j,1)=filtrado2011_fecha_conv(k,1);
fecha2011_anomalias_anillosgen(j,2)=filtrado2011_fecha_conv(k,2);
fecha2011_anomalias_anillosgen(j,3)=filtrado2011_fecha_conv(k,3);
fecha2011_anomalias_anillosgen(j,4)=filtrado2011_fecha_conv(k,4);
fecha2011_anomalias_anillosgen(j,5)=filtrado2011_fecha_conv(k,5);
fecha2011_anomalias_anillosgen(j,6)=filtrado2011_fecha_conv(k,6);
                i=i+1;
                j=j+1;
            end
            i=i+1;
        end
    end
end
[nsamples m]=size(detector_filtrado);
figure(33)
plot(1:m, detector_filtrado);

figure(34)
plot(1:m,detector,1:m,detector_filtrado,'g');
legend('falsas alarmas', 'alarmas reales');

detector2011_anillosgen=detector;
detector_filtrado2011_anillosgen=detector_filtrado;

```

-Paso de palas:

```

clear all
close all
clc

```

```

load('filtrado2011_angulo_palas.mat');
load('filtrado2011_vel_viento.mat');
load('filtrado2011_pot_total.mat');
load('filtrado2011_angulo_viento.mat');
load('model_svm_pasopalas.mat');
load('dt_pasopalas.mat');
load('filtrado2011_fecha_conv');

```

```

%[nsamples m]=size(data);

```

```

[nsamples m]=size(filtrado2011_angulo_palas);
t=1:nsamples;
% nsamples=3000;

```

```

%plot(t, data(:,1), t, data(:,2), t, data(:,3))

```

```

figure(1)
plot(t, filtrado2011_angulo_palas, t, filtrado2011_vel_viento, t,
filtrado2011_pot_total, t, filtrado2011_angulo_viento)
ylabel('Magnitude'); xlabel('Sample');
legend('tem_aceite_multi', 'tem_interior_nac', 'pot_total',
'vel_viento');
title(' Variables');
Xt=zeros(nsamples,3); %Only first training samples
Xt(:,1)=filtrado2011_vel_viento(1:nsamples);
Xt(:,2)=filtrado2011_pot_total(1:nsamples);
Xt(:,3)=filtrado2011_angulo_viento(1:nsamples);

Tt=zeros(nsamples,1); %Only first 4000 samples
Tt(:,1)=filtrado2011_angulo_palas(1:nsamples);
%Tt(:,2)=data(june+1:nsamples,9);
%Tt=data(june+1:nsamples,9);
% Tt=Tt';
% Xt=Xt';

Pt = predict(model_svm_pasopalas,Xt);

% Se representa la salida estimada por la red para las entradas dadas
y
% también lo que tendría que haber dado

figure(30);
%plot(X,T, 'sr',X,Z, 'X')

plot(1:nsamples, Tt(:,1),1:nsamples, Pt(:,1),1:nsamples,
Pt(:,1)+2*dt_pasopalas,'m', 1:nsamples, Pt(:,1)-2*dt_pasopalas,'m');

ylabel('Temperature %'); xlabel('Sample');
legend('Real Value', 'Estimated Value', 'Error margin')
title(' Neural network test with unknown cases');

figure(31)
histogram(Tt(:,1)-Pt(:,1))
ylabel('Frecuency'); xlabel('Samples');
title(' Histogram of error with unknown data');

dt_pasopalas=std(Tt-Pt);
media_pasopalas=mean(Tt-Pt);
error_cuadratico_pasopalas=mse(Tt-Pt);

i=1;
j=1;
f(j)=0;
nf=0;
for k=1:20344
    if(Tt(i)>Pt(i)+2*dt_pasopalas)|(Tt(i)<Pt(i)-2*dt_pasopalas)
        detector(i)=1;
        f(j)=f(j)+1;
        nf=nf+1;
    end
    if(Tt(i)<Pt(i)+2*dt_pasopalas)&(Tt(i)>Pt(i)-2*dt_pasopalas)
        detector(i)=0;
        j=j+1;
        f(j)=0;
    end
end
i=i+1;

```

```

end
[m n]=size(f);
i=1;
c=1;
for k=1:n
    if(f(i)>0)
        c=c+1;
    end
    i=i+1;
end

figure(32)
plot(1:nsamples, detector);

[m nsamples]=size(f);
i=1;
j=1;
for k=1:nsamples
    t=f(k);
    if(k==1)
        if(t==0)
            detector_filtrado(i)=0;
        end
        if(t>0)
            for l=1:t
                detector_filtrado(i)=0;
                i=i+1;
            end
        end
    end
    if(k>1)
        if(t==0)
            detector_filtrado(i)=0;
            i=i+1;
        end
        if(t>0)&(t<3)
            for l=1:t
                detector_filtrado(i)=0;
                i=i+1;
            end
            i=i+1;
        end
        if(t>2)
            for l=1:t
                detector_filtrado(i)=1;
            end
        end
    end
    fecha2011_anomalias_pasopalas(j,1)=filtrado2011_fecha_conv(k,1);
    fecha2011_anomalias_pasopalas(j,2)=filtrado2011_fecha_conv(k,2);
    fecha2011_anomalias_pasopalas(j,3)=filtrado2011_fecha_conv(k,3);
    fecha2011_anomalias_pasopalas(j,4)=filtrado2011_fecha_conv(k,4);
    fecha2011_anomalias_pasopalas(j,5)=filtrado2011_fecha_conv(k,5);
    fecha2011_anomalias_pasopalas(j,6)=filtrado2011_fecha_conv(k,6);
    i=i+1;
    j=j+1;
end
i=i+1;

```

```

        end
    end
end

[nsamples m]=size(detector_filtrado);
figure(33)
plot(1:m, detector_filtrado);

figure(34)
plot(1:m,detector,1:m,detector_filtrado,'g');
legend('falsas alarmas', 'alarmas reales');

detector2011_pasopalas=detector;
detector_filtrado2011_pasopalas=detector_filtrado;

```

-Rodamiento DE del generador

```

clear all
close all
clc

load('filtrado2011_tem_rod_DE_gen.mat');
load('filtrado2011_tem_interior_nac.mat');
load('filtrado2011_pot_total.mat');
load('filtrado2011_vel_viento.mat');
load('model_svm_rodgen_de.mat');
load('dt_rodgen_de.mat');
load('filtrado2011_fecha_conv');

%[nsamples m]=size(data);

[nsamples m]=size(filtrado2011_tem_rod_DE_gen);
t=1:nsamples;
% nsamples=3000;

%plot(t, data(:,1), t, data(:,2), t, data(:,3))

figure(1)
plot(t, filtrado2011_tem_rod_DE_gen, t, filtrado2011_tem_interior_nac,
t, filtrado2011_pot_total, t, filtrado2011_vel_viento)
ylabel('Magnitude'); xlabel('Sample');
legend('tem_aceite_multi', 'tem_interior_nac', 'pot_total',
'vel_viento');
title(' Variables');
Xt=zeros(nsamples,3); %Only first training samples
Xt(:,1)=filtrado2011_tem_interior_nac(1:nsamples);
Xt(:,2)=filtrado2011_pot_total(1:nsamples);
Xt(:,3)=filtrado2011_vel_viento(1:nsamples);

Tt=zeros(nsamples,1); %Only first 4000 samples
Tt(:,1)=filtrado2011_tem_rod_DE_gen(1:nsamples);
%Tt(:,2)=data(june+1:nsamples,9);
%Tt=data(june+1:nsamples,9);
% Tt=Tt';

```

```

% Xt=Xt';

Pt = predict(model_svm_rodgen_de,Xt);

% Se representa la salida estimada por la red para las entradas dadas
y
% también lo que tendría que haber dado

figure(30);
%plot(X,T, 'sr',X,Z,'X')

plot(1:nsamples, Tt(:,1),1:nsamples, Pt(:,1),1:nsamples,
Pt(:,1)+2*dt_rodgen_de,'m', 1:nsamples, Pt(:,1)-2*dt_rodgen_de,'m');

ylabel('Temperature %'); xlabel('Sample');
legend('Real Value', 'Estimated Value', 'Error margin')
title(' Neural network test with unknown cases');

figure(31)
histogram(Tt(:,1)-Pt(:,1))
ylabel('Frecuency'); xlabel('Samples');
title(' Histogram of error with unknown data');

dt_rodgen_de=std(Tt-Pt);
media_rodgen_de=mean(Tt-Pt);
error_cuadratico_rodgen_de=mse(Tt-Pt);

i=1;
j=1;
f(j)=0;
nf=0;
for k=1:20344
    if (Tt(i)>Pt(i)+2*dt_rodgen_de)|(Tt(i)<Pt(i)-2*dt_rodgen_de)
        detector(i)=1;
        f(j)=f(j)+1;
        nf=nf+1;
    end
    if (Tt(i)<Pt(i)+2*dt_rodgen_de)&(Tt(i)>Pt(i)-2*dt_rodgen_de)
        detector(i)=0;
        j=j+1;
        f(j)=0;
    end
    i=i+1;
end
[m n]=size(f);
i=1;
c=1;
for k=1:n
    if (f(i)>0)
        c=c+1;
    end
    i=i+1;
end

figure(32)
plot(1:nsamples, detector);

[m nsamples]=size(f);
i=1;

```

```

j=1;
for k=1:nsamples
    t=f(k);
    if(k==1)
        if(t==0)
            detector_filtrado(i)=0;
        end
        if(t>0)
            for l=1:t
                detector_filtrado(i)=0;
                i=i+1;
            end
        end
    end
    if(k>1)
        if(t==0)
            detector_filtrado(i)=0;
            i=i+1;
        end
        if(t>0)&(t<3)
            for l=1:t
                detector_filtrado(i)=0;
                i=i+1;
            end
            i=i+1;
        end
        if(t>2)
            for l=1:t
                detector_filtrado(i)=1;
            end
        end
    end
    fecha2011_anomalias_rodgen_de(j,1)=filtrado2011_fecha_conv(k,1);
    fecha2011_anomalias_rodgen_de(j,2)=filtrado2011_fecha_conv(k,2);
    fecha2011_anomalias_rodgen_de(j,3)=filtrado2011_fecha_conv(k,3);
    fecha2011_anomalias_rodgen_de(j,4)=filtrado2011_fecha_conv(k,4);
    fecha2011_anomalias_rodgen_de(j,5)=filtrado2011_fecha_conv(k,5);
    fecha2011_anomalias_rodgen_de(j,6)=filtrado2011_fecha_conv(k,6);
    i=i+1;
    j=j+1;
end
i=i+1;
end
end

[nsamples m]=size(detector_filtrado);
figure(33)
plot(1:m, detector_filtrado);

figure(34)
plot(1:m,detector,1:m,detector_filtrado,'g');
legend('falsas alarmas', 'alarmas reales');

detector2011_rodgen_de=detector;
detector_filtrado2011_rodgen_de=detector_filtrado;

```

-Rodamiento NDE del generador:

```
clear all
close all
clc

load('filtrado2011_tem_rod_NDE_gen.mat');
load('filtrado2011_tem_interior_nac.mat');
load('filtrado2011_pot_total.mat');
load('filtrado2011_vel_viento.mat');
load('model_svm_rodgen_nde.mat');
load('dt_rodgen_nde.mat');
load('filtrado2011_fecha_conv');

%[nsamples m]=size(data);

[nsamples m]=size(filtrado2011_tem_rod_NDE_gen);
t=1:nsamples;
% nsamples=3000;

%plot(t, data(:,1), t, data(:,2), t, data(:,3))

figure(1)
plot(t, filtrado2011_tem_rod_NDE_gen, t,
filtrado2011_tem_interior_nac, t, filtrado2011_pot_total, t,
filtrado2011_vel_viento)
ylabel('Magnitud'); xlabel('Sample');
legend('tem_aceite_multi', 'tem_interior_nac', 'pot_total',
'vel_viento');
title(' Variables');
Xt=zeros(nsamples,3); %Only first training samples
Xt(:,1)=filtrado2011_tem_interior_nac(1:nsamples);
Xt(:,2)=filtrado2011_pot_total(1:nsamples);
Xt(:,3)=filtrado2011_vel_viento(1:nsamples);

Tt=zeros(nsamples,1); %Only first 4000 samples
Tt(:,1)=filtrado2011_tem_rod_NDE_gen(1:nsamples);
%Tt(:,2)=data(june+1:nsamples,9);
%Tt=data(june+1:nsamples,9);
% Tt=Tt';
% Xt=Xt';

Pt = predict(model_svm_rodgen_nde,Xt);

% Se representa la salida estimada por la red para las entradas dadas
y
% también lo que tendría que haber dado

figure(30);
%plot(X,T, 'sr',X,Z,'X')

plot(1:nsamples, Tt(:,1),1:nsamples, Pt(:,1),1:nsamples,
Pt(:,1)+2*dt_rodgen_nde,'m', 1:nsamples, Pt(:,1)-2*dt_rodgen_nde,'m');
```

```

ylabel('Temperature %'); xlabel('Sample');
legend('Real Value', 'Estimated Value', 'Error margin')
title(' Neural network test with unknown cases');

figure(31)
histogram(Tt(:,1)-Pt(:,1))
ylabel('Frecuency'); xlabel('Samples');
title(' Histogram of error with unknown data');

dt_rodgen_nde=std(Tt-Pt);
media_rodgen_nde=mean(Tt-Pt);
error_cuadratico_rodgen_nde=mse(Tt-Pt);

i=1;
j=1;
f(j)=0;
nf=0;
for k=1:20344
    if(Tt(i)>Pt(i)+2*dt_rodgen_nde)|(Tt(i)<Pt(i)-2*dt_rodgen_nde)
        detector(i)=1;
        f(j)=f(j)+1;
        nf=nf+1;
    end
    if(Tt(i)<Pt(i)+2*dt_rodgen_nde)&(Tt(i)>Pt(i)-2*dt_rodgen_nde)
        detector(i)=0;
        j=j+1;
        f(j)=0;
    end
    i=i+1;
end
[m n]=size(f);
i=1;
c=1;
for k=1:n
    if(f(i)>0)
        c=c+1;
    end
    i=i+1;
end

figure(32)
plot(1:nsamples, detector);

[m nsamples]=size(f);
i=1;
j=1;
for k=1:nsamples
    t=f(k);
    if(k==1)
        if(t==0)
            detector_filtrado(i)=0;
        end
        if(t>0)
            for l=1:t
                detector_filtrado(i)=0;
                i=i+1;
            end
        end
    end
    if(k>1)

```

```

        if(t==0)
            detector_filtrado(i)=0;
            i=i+1;
        end
        if(t>0)&(t<3)
            for l=1:t
                detector_filtrado(i)=0;
                i=i+1;
            end
            i=i+1;
        end
        if(t>2)
            for l=1:t
                detector_filtrado(i)=1;
            end
        end

        fecha2011_anomalias_rodgen_nde(j,1)=filtrado2011_fecha_conv(k,1);
        fecha2011_anomalias_rodgen_nde(j,2)=filtrado2011_fecha_conv(k,2);
        fecha2011_anomalias_rodgen_nde(j,3)=filtrado2011_fecha_conv(k,3);
        fecha2011_anomalias_rodgen_nde(j,4)=filtrado2011_fecha_conv(k,4);
        fecha2011_anomalias_rodgen_nde(j,5)=filtrado2011_fecha_conv(k,5);
        fecha2011_anomalias_rodgen_nde(j,6)=filtrado2011_fecha_conv(k,6);
        i=i+1;
        j=j+1;
    end
    i=i+1;
end
end

[nsamples m]=size(detector_filtrado);
figure(33)
plot(1:m, detector_filtrado);

figure(34)
plot(1:m,detector,1:m,detector_filtrado,'g');
legend('falsas alarmas', 'alarmas reales');

detector2011_rodgen_nde=detector;
detector_filtrado2011_rodgen_nde=detector_filtrado;

```

-Rodamiento de la multiplicadora:

```

clear all
close all
clc

load('filtrado2011_tem_rod_alta_multi.mat');
load('filtrado2011_tem_interior_nac.mat');
load('filtrado2011_pot_total.mat');
load('filtrado2011_vel_viento.mat');
load('model_svm_rodmulti.mat');
load('dt_rodmulti.mat');
load('filtrado2011_fecha_conv');

```

```

%[nsamples m]=size(data);

[nsamples m]=size(filtrado2011_tem_rod_alta_multi);
t=1:nsamples;
% nsamples=3000;

%plot(t, data(:,1), t, data(:,2), t, data(:,3))

figure(1)
plot(t, filtrado2011_tem_rod_alta_multi, t,
filtrado2011_tem_interior_nac, t, filtrado2011_pot_total, t,
filtrado2011_vel_viento)
ylabel('Magnitude'); xlabel('Sample');
legend('tem_aceite_multi', 'tem_interior_nac', 'pot_total',
'vel_viento');
title(' Variables');
Xt=zeros(nsamples,3); %Only first training samples
Xt(:,1)=filtrado2011_tem_interior_nac(1:nsamples);
Xt(:,2)=filtrado2011_pot_total(1:nsamples);
Xt(:,3)=filtrado2011_vel_viento(1:nsamples);

Tt=zeros(nsamples,1); %Only first 4000 samples
Tt(:,1)=filtrado2011_tem_rod_alta_multi(1:nsamples);
%Tt(:,2)=data(june+1:nsamples,9);
%Tt=data(june+1:nsamples,9);
% Tt=Tt';
% Xt=Xt';

Pt = predict(model_svm_rodmulti,Xt);

% Se representa la salida estimada por la red para las entradas dadas
y
% también lo que tendría que haber dado

figure(30);
%plot(X,T, 'sr',X,Z, 'X')

plot(1:nsamples, Tt(:,1),1:nsamples, Pt(:,1),1:nsamples,
Pt(:,1)+2*dt_rodmulti, 'm', 1:nsamples, Pt(:,1)-2*dt_rodmulti, 'm');

ylabel('Temperature %'); xlabel('Sample');
legend('Real Value', 'Estimated Value', 'Error margin')
title(' Neural network test with unknown cases');

figure(31)
histogram(Tt(:,1)-Pt(:,1))
ylabel('Frecuency'); xlabel('Samples');
title(' Histogram of error with unknown data');

dt_rodmulti=std(Tt-Pt);
media_rodmulti=mean(Tt-Pt);
error_cuadratico_rodmulti=mse(Tt-Pt);

i=1;

```

```

j=1;
f(j)=0;
nf=0;
for k=1:20344
    if (Tt(i)>Pt(i)+2*dt_rodmulti)|(Tt(i)<Pt(i)-2*dt_rodmulti)
        detector(i)=1;
        f(j)=f(j)+1;
        nf=nf+1;
    end
    if (Tt(i)<Pt(i)+2*dt_rodmulti)&(Tt(i)>Pt(i)-2*dt_rodmulti)
        detector(i)=0;
        j=j+1;
        f(j)=0;
    end
end
i=i+1;
end
[m n]=size(f);
i=1;
c=1;
for k=1:n
    if (f(i)>0)
        c=c+1;
    end
    i=i+1;
end

```

```

figure(32)
plot(1:nsamples, detector);

```

```

[m nsamples]=size(f);
i=1;
j=1;
for k=1:nsamples
    t=f(k);
    if (k==1)
        if (t==0)
            detector_filtrado(i)=0;
        end
        if (t>0)
            for l=1:t
                detector_filtrado(i)=0;
                i=i+1;
            end
        end
    end
    if (k>1)
        if (t==0)
            detector_filtrado(i)=0;
            i=i+1;
        end
        if (t>0)&(t<3)
            for l=1:t
                detector_filtrado(i)=0;
                i=i+1;
            end
            i=i+1;
        end
        if (t>2)
            for l=1:t
                detector_filtrado(i)=1;
            end
        end
    end
end

```

```

fecha2011_anomalias_rodmulti(j,1)=filtrado2011_fecha_conv(k,1);
fecha2011_anomalias_rodmulti(j,2)=filtrado2011_fecha_conv(k,2);
fecha2011_anomalias_rodmulti(j,3)=filtrado2011_fecha_conv(k,3);
fecha2011_anomalias_rodmulti(j,4)=filtrado2011_fecha_conv(k,4);
fecha2011_anomalias_rodmulti(j,5)=filtrado2011_fecha_conv(k,5);
fecha2011_anomalias_rodmulti(j,6)=filtrado2011_fecha_conv(k,6);
        i=i+1;
        j=j+1;
    end
    i=i+1;
end
end
end

```

```

[nsamples m]=size(detector_filtrado);
figure(33)
plot(1:m, detector_filtrado);

```

```

figure(34)
plot(1:m,detector,1:m,detector_filtrado,'g');
legend('falsas alarmas', 'alarmas reales');

```

```

detector2011_rodmulti=detector;
detector_filtrado2011_rodmulti=detector_filtrado;

```

Utilizando todos los modelos para realizar la toma de decisiones

-Aceite de la multiplicadora:

```

clear all
close all
clc

```

```

load('detector_filtrado2011_aceite_multi_preceptron.mat');
load('detector_filtrado2011_aceite_multi_rbf.mat');
load('detector_filtrado2011_aceite_multi_svm.mat');
load('filtrado2011_fecha_conv');

```

```

[m n]=size(detector_filtrado2011_aceite_multi_preceptron);

```

```

figure(1)
plot(1:n, detector_filtrado2011_aceite_multi_preceptron,'b',1:n,
detector_filtrado2011_aceite_multi_rbf,'g',1:n,detector_filtrado2011_a
ceite_multi_svm,'r');
legend('alarma perceptron', 'alarma RBF', 'alarma SVM')

```

```

j=1;
for k=1:n;

```

```

if(detector_filtrado2011_aceite_multi_preceptron(k)>0)&(detector_filtr
ado2011_aceite_multi_rbf(k)>0)&(detector_filtrado2011_aceite_multi_svm
(k)>0)

```

```

        detector(k)=3;

        fecha2011_anomalias_aceite_multi(j,1)=filtrado2011_fecha_conv(k,1);
        fecha2011_anomalias_aceite_multi(j,2)=filtrado2011_fecha_conv(k,2);
        fecha2011_anomalias_aceite_multi(j,3)=filtrado2011_fecha_conv(k,3);
        fecha2011_anomalias_aceite_multi(j,4)=filtrado2011_fecha_conv(k,4);
        fecha2011_anomalias_aceite_multi(j,5)=filtrado2011_fecha_conv(k,5);
        fecha2011_anomalias_aceite_multi(j,6)=filtrado2011_fecha_conv(k,6);
        j=j+1;
    end

    if(detector_filtrado2011_aceite_multi_preceptron(k)>0)&(detector_filtrado2011_aceite_multi_rbf(k)>0)&(detector_filtrado2011_aceite_multi_svm(k)==0)
        detector(k)=2;

        fecha2011_anomalias_aceite_multi(j,1)=filtrado2011_fecha_conv(k,1);
        fecha2011_anomalias_aceite_multi(j,2)=filtrado2011_fecha_conv(k,2);
        fecha2011_anomalias_aceite_multi(j,3)=filtrado2011_fecha_conv(k,3);
        fecha2011_anomalias_aceite_multi(j,4)=filtrado2011_fecha_conv(k,4);
        fecha2011_anomalias_aceite_multi(j,5)=filtrado2011_fecha_conv(k,5);
        fecha2011_anomalias_aceite_multi(j,6)=filtrado2011_fecha_conv(k,6);
        j=j+1;
    end

    if(detector_filtrado2011_aceite_multi_preceptron(k)>0)&(detector_filtrado2011_aceite_multi_rbf(k)==0)&(detector_filtrado2011_aceite_multi_svm(k)>0)
        detector(k)=2;

        fecha2011_anomalias_aceite_multi(j,1)=filtrado2011_fecha_conv(k,1);
        fecha2011_anomalias_aceite_multi(j,2)=filtrado2011_fecha_conv(k,2);
        fecha2011_anomalias_aceite_multi(j,3)=filtrado2011_fecha_conv(k,3);
        fecha2011_anomalias_aceite_multi(j,4)=filtrado2011_fecha_conv(k,4);
        fecha2011_anomalias_aceite_multi(j,5)=filtrado2011_fecha_conv(k,5);
        fecha2011_anomalias_aceite_multi(j,6)=filtrado2011_fecha_conv(k,6);
        j=j+1;
    end

    if(detector_filtrado2011_aceite_multi_preceptron(k)==0)&(detector_filtrado2011_aceite_multi_rbf(k)>0)&(detector_filtrado2011_aceite_multi_svm(k)>0)
        detector(k)=2;

        fecha2011_anomalias_aceite_multi(j,1)=filtrado2011_fecha_conv(k,1);

```

```

fecha2011_anomalias_aceite_multi(j,2)=filtrado2011_fecha_conv(k,2);
fecha2011_anomalias_aceite_multi(j,3)=filtrado2011_fecha_conv(k,3);
fecha2011_anomalias_aceite_multi(j,4)=filtrado2011_fecha_conv(k,4);
fecha2011_anomalias_aceite_multi(j,5)=filtrado2011_fecha_conv(k,5);
fecha2011_anomalias_aceite_multi(j,6)=filtrado2011_fecha_conv(k,6);
    j=j+1;
end

if(detector_filtrado2011_aceite_multi_preceptron(k)==0)&(detector_filtrado2011_aceite_multi_rbf(k)==0)&(detector_filtrado2011_aceite_multi_svm(k)>0)
    detector(k)=1;
end

if(detector_filtrado2011_aceite_multi_preceptron(k)==0)&(detector_filtrado2011_aceite_multi_rbf(k)>0)&(detector_filtrado2011_aceite_multi_svm(k)==0)
    detector(k)=1;
end

if(detector_filtrado2011_aceite_multi_preceptron(k)>0)&(detector_filtrado2011_aceite_multi_rbf(k)==0)&(detector_filtrado2011_aceite_multi_svm(k)==0)
    detector(k)=1;
end

if(detector_filtrado2011_aceite_multi_preceptron(k)==0)&(detector_filtrado2011_aceite_multi_rbf(k)==0)&(detector_filtrado2011_aceite_multi_svm(k)==0)
    detector(k)=0;
end
end

figure(2)
plot(1:n, detector);

detectortotal_2011_aceite_multi=detector;

```

-Anillos del generador

```

clear all
close all
clc

load('detector_filtrado2011_anillosgen_preceptron.mat');
load('detector_filtrado2011_anillosgen_rbf.mat');
load('detector_filtrado2011_anillosgen_svm.mat');
load('filtrado2011_fecha_conv');

[m n]=size(detector_filtrado2011_anillosgen_preceptron);

figure(1)

```

```

plot(1:n, detector_filtrado2011_anillosgen_preceptron, 'b', 1:n,
detector_filtrado2011_anillosgen_rbf, 'g', 1:n, detector_filtrado2011_anillosgen_svm, 'r');
legend('alarma perceptron', 'alarma RBF', 'alarma SVM')
j=1;

for k=1:n;

if(detector_filtrado2011_anillosgen_preceptron(k)>0)&(detector_filtrado2011_anillosgen_rbf(k)>0)&(detector_filtrado2011_anillosgen_svm(k)>0)
    detector(k)=3;

    fecha2011_anomalias_anillosgen(j,1)=filtrado2011_fecha_conv(k,1);
    fecha2011_anomalias_anillosgen(j,2)=filtrado2011_fecha_conv(k,2);
    fecha2011_anomalias_anillosgen(j,3)=filtrado2011_fecha_conv(k,3);
    fecha2011_anomalias_anillosgen(j,4)=filtrado2011_fecha_conv(k,4);
    fecha2011_anomalias_anillosgen(j,5)=filtrado2011_fecha_conv(k,5);
    fecha2011_anomalias_anillosgen(j,6)=filtrado2011_fecha_conv(k,6);
    j=j+1;
end

if(detector_filtrado2011_anillosgen_preceptron(k)>0)&(detector_filtrado2011_anillosgen_rbf(k)>0)&(detector_filtrado2011_anillosgen_svm(k)==0)
    detector(k)=2;

    fecha2011_anomalias_anillosgen(j,1)=filtrado2011_fecha_conv(k,1);
    fecha2011_anomalias_anillosgen(j,2)=filtrado2011_fecha_conv(k,2);
    fecha2011_anomalias_anillosgen(j,3)=filtrado2011_fecha_conv(k,3);
    fecha2011_anomalias_anillosgen(j,4)=filtrado2011_fecha_conv(k,4);
    fecha2011_anomalias_anillosgen(j,5)=filtrado2011_fecha_conv(k,5);
    fecha2011_anomalias_anillosgen(j,6)=filtrado2011_fecha_conv(k,6);
    j=j+1;
end

if(detector_filtrado2011_anillosgen_preceptron(k)>0)&(detector_filtrado2011_anillosgen_rbf(k)==0)&(detector_filtrado2011_anillosgen_svm(k)>0)
    detector(k)=2;

    fecha2011_anomalias_anillosgen(j,1)=filtrado2011_fecha_conv(k,1);
    fecha2011_anomalias_anillosgen(j,2)=filtrado2011_fecha_conv(k,2);
    fecha2011_anomalias_anillosgen(j,3)=filtrado2011_fecha_conv(k,3);
    fecha2011_anomalias_anillosgen(j,4)=filtrado2011_fecha_conv(k,4);
    fecha2011_anomalias_anillosgen(j,5)=filtrado2011_fecha_conv(k,5);
    fecha2011_anomalias_anillosgen(j,6)=filtrado2011_fecha_conv(k,6);

```

```

        j=j+1;
    end

    if(detector_filtrado2011_anillosgen_preceptron(k)==0)&(detector_filtrado2011_anillosgen_rbf(k)>0)&(detector_filtrado2011_anillosgen_svm(k)>0)
        detector(k)=2;

    fecha2011_anomalias_anillosgen(j,1)=filtrado2011_fecha_conv(k,1);
    fecha2011_anomalias_anillosgen(j,2)=filtrado2011_fecha_conv(k,2);
    fecha2011_anomalias_anillosgen(j,3)=filtrado2011_fecha_conv(k,3);
    fecha2011_anomalias_anillosgen(j,4)=filtrado2011_fecha_conv(k,4);
    fecha2011_anomalias_anillosgen(j,5)=filtrado2011_fecha_conv(k,5);
    fecha2011_anomalias_anillosgen(j,6)=filtrado2011_fecha_conv(k,6);
    j=j+1;
    end

    if(detector_filtrado2011_anillosgen_preceptron(k)==0)&(detector_filtrado2011_anillosgen_rbf(k)==0)&(detector_filtrado2011_anillosgen_svm(k)>0)
        detector(k)=1;
    end

    if(detector_filtrado2011_anillosgen_preceptron(k)==0)&(detector_filtrado2011_anillosgen_rbf(k)>0)&(detector_filtrado2011_anillosgen_svm(k)==0)
        detector(k)=1;
    end

    if(detector_filtrado2011_anillosgen_preceptron(k)>0)&(detector_filtrado2011_anillosgen_rbf(k)==0)&(detector_filtrado2011_anillosgen_svm(k)==0)
        detector(k)=1;
    end

    if(detector_filtrado2011_anillosgen_preceptron(k)==0)&(detector_filtrado2011_anillosgen_rbf(k)==0)&(detector_filtrado2011_anillosgen_svm(k)==0)
        detector(k)=0;
    end
end

figure(2)
plot(1:n, detector);

detectortotal_2011_anillosgen=detector;

```

-Paso de palas:

```

clear all
close all
clc

```

```

load('detector_filtrado2011_pasopalas_preceptron.mat');
load('detector_filtrado2011_pasopalas_rbf.mat');

```

```

load('detector_filtrado2011_pasopalas_svm.mat');
load('filtrado2011_fecha_conv');

[m n]=size(detector_filtrado2011_pasopalas_preceptron);

figure(1)
plot(1:n, detector_filtrado2011_pasopalas_preceptron, 'b', 1:n,
detector_filtrado2011_pasopalas_rbf, 'g', 1:n, detector_filtrado2011_pasopalas_svm, 'r');
legend('alarma perceptron', 'alarma RBF', 'alarma SVM')
j=1;

for k=1:n;

if(detector_filtrado2011_pasopalas_preceptron(k)>0)&(detector_filtrado2011_pasopalas_rbf(k)>0)&(detector_filtrado2011_pasopalas_svm(k)>0)
    detector(k)=3;

fecha2011_anomalias_pasopalas(j,1)=filtrado2011_fecha_conv(k,1);
fecha2011_anomalias_pasopalas(j,2)=filtrado2011_fecha_conv(k,2);
fecha2011_anomalias_pasopalas(j,3)=filtrado2011_fecha_conv(k,3);
fecha2011_anomalias_pasopalas(j,4)=filtrado2011_fecha_conv(k,4);
fecha2011_anomalias_pasopalas(j,5)=filtrado2011_fecha_conv(k,5);
fecha2011_anomalias_pasopalas(j,6)=filtrado2011_fecha_conv(k,6);
    j=j+1;
end

if(detector_filtrado2011_pasopalas_preceptron(k)>0)&(detector_filtrado2011_pasopalas_rbf(k)>0)&(detector_filtrado2011_pasopalas_svm(k)==0)
    detector(k)=2;

fecha2011_anomalias_pasopalas(j,1)=filtrado2011_fecha_conv(k,1);
fecha2011_anomalias_pasopalas(j,2)=filtrado2011_fecha_conv(k,2);
fecha2011_anomalias_pasopalas(j,3)=filtrado2011_fecha_conv(k,3);
fecha2011_anomalias_pasopalas(j,4)=filtrado2011_fecha_conv(k,4);
fecha2011_anomalias_pasopalas(j,5)=filtrado2011_fecha_conv(k,5);
fecha2011_anomalias_pasopalas(j,6)=filtrado2011_fecha_conv(k,6);
    j=j+1;
end

if(detector_filtrado2011_pasopalas_preceptron(k)>0)&(detector_filtrado2011_pasopalas_rbf(k)==0)&(detector_filtrado2011_pasopalas_svm(k)>0)
    detector(k)=2;

fecha2011_anomalias_pasopalas(j,1)=filtrado2011_fecha_conv(k,1);
fecha2011_anomalias_pasopalas(j,2)=filtrado2011_fecha_conv(k,2);
fecha2011_anomalias_pasopalas(j,3)=filtrado2011_fecha_conv(k,3);
fecha2011_anomalias_pasopalas(j,4)=filtrado2011_fecha_conv(k,4);

```

```

fecha2011_anomalias_pasopalas(j,5)=filtrado2011_fecha_conv(k,5);
fecha2011_anomalias_pasopalas(j,6)=filtrado2011_fecha_conv(k,6);
    j=j+1;
end

if(detector_filtrado2011_pasopalas_preceptron(k)==0)&(detector_filtrado2011_pasopalas_rbf(k)>0)&(detector_filtrado2011_pasopalas_svm(k)>0)
    detector(k)=2;

fecha2011_anomalias_pasopalas(j,1)=filtrado2011_fecha_conv(k,1);
fecha2011_anomalias_pasopalas(j,2)=filtrado2011_fecha_conv(k,2);
fecha2011_anomalias_pasopalas(j,3)=filtrado2011_fecha_conv(k,3);
fecha2011_anomalias_pasopalas(j,4)=filtrado2011_fecha_conv(k,4);
fecha2011_anomalias_pasopalas(j,5)=filtrado2011_fecha_conv(k,5);
fecha2011_anomalias_pasopalas(j,6)=filtrado2011_fecha_conv(k,6);
    j=j+1;
end

if(detector_filtrado2011_pasopalas_preceptron(k)==0)&(detector_filtrado2011_pasopalas_rbf(k)==0)&(detector_filtrado2011_pasopalas_svm(k)>0)
    detector(k)=1;
end

if(detector_filtrado2011_pasopalas_preceptron(k)==0)&(detector_filtrado2011_pasopalas_rbf(k)>0)&(detector_filtrado2011_pasopalas_svm(k)==0)
    detector(k)=1;
end

if(detector_filtrado2011_pasopalas_preceptron(k)>0)&(detector_filtrado2011_pasopalas_rbf(k)==0)&(detector_filtrado2011_pasopalas_svm(k)==0)
    detector(k)=1;
end

if(detector_filtrado2011_pasopalas_preceptron(k)==0)&(detector_filtrado2011_pasopalas_rbf(k)==0)&(detector_filtrado2011_pasopalas_svm(k)==0)
    detector(k)=0;
end
end

figure(2)
plot(1:n, detector);

detectortotal_2011_pasopalas=detector;

```

-Rodamiento DE del generador

```

clear all
close all
clc

```

```

load('detector_filtrado2011_rodgen_de_preceptron.mat');
load('detector_filtrado2011_rodgen_de_rbf.mat');

```

```

load('detector_filtrado2011_rodgen_de_svm.mat');
load('filtrado2011_fecha_conv');

[m n]=size(detector_filtrado2011_rodgen_de_preceptron);

figure(1)
plot(1:n, detector_filtrado2011_rodgen_de_preceptron, 'b', 1:n,
detector_filtrado2011_rodgen_de_rbf, 'g', 1:n, detector_filtrado2011_rodg
en_de_svm, 'r');
legend('alarma perceptron', 'alarma RBF', 'alarma SVM')
j=1;

for k=1:n;

if(detector_filtrado2011_rodgen_de_preceptron(k)>0)&(detector_filtrado
2011_rodgen_de_rbf(k)>0)&(detector_filtrado2011_rodgen_de_svm(k)>0)
    detector(k)=3;

fecha2011_anomalias_rodgen_de(j,1)=filtrado2011_fecha_conv(k,1);
fecha2011_anomalias_rodgen_de(j,2)=filtrado2011_fecha_conv(k,2);
fecha2011_anomalias_rodgen_de(j,3)=filtrado2011_fecha_conv(k,3);
fecha2011_anomalias_rodgen_de(j,4)=filtrado2011_fecha_conv(k,4);
fecha2011_anomalias_rodgen_de(j,5)=filtrado2011_fecha_conv(k,5);
fecha2011_anomalias_rodgen_de(j,6)=filtrado2011_fecha_conv(k,6);
    j=j+1;
end

if(detector_filtrado2011_rodgen_de_preceptron(k)>0)&(detector_filtrado
2011_rodgen_de_rbf(k)>0)&(detector_filtrado2011_rodgen_de_svm(k)==0)
    detector(k)=2;

fecha2011_anomalias_rodgen_de(j,1)=filtrado2011_fecha_conv(k,1);
fecha2011_anomalias_rodgen_de(j,2)=filtrado2011_fecha_conv(k,2);
fecha2011_anomalias_rodgen_de(j,3)=filtrado2011_fecha_conv(k,3);
fecha2011_anomalias_rodgen_de(j,4)=filtrado2011_fecha_conv(k,4);
fecha2011_anomalias_rodgen_de(j,5)=filtrado2011_fecha_conv(k,5);
fecha2011_anomalias_rodgen_de(j,6)=filtrado2011_fecha_conv(k,6);
    j=j+1;
end

if(detector_filtrado2011_rodgen_de_preceptron(k)>0)&(detector_filtrado
2011_rodgen_de_rbf(k)==0)&(detector_filtrado2011_rodgen_de_svm(k)>0)
    detector(k)=2;

fecha2011_anomalias_rodgen_de(j,1)=filtrado2011_fecha_conv(k,1);
fecha2011_anomalias_rodgen_de(j,2)=filtrado2011_fecha_conv(k,2);
fecha2011_anomalias_rodgen_de(j,3)=filtrado2011_fecha_conv(k,3);
fecha2011_anomalias_rodgen_de(j,4)=filtrado2011_fecha_conv(k,4);

```

```

fecha2011_anomalias_rodgen_de(j,5)=filtrado2011_fecha_conv(k,5);
fecha2011_anomalias_rodgen_de(j,6)=filtrado2011_fecha_conv(k,6);
    j=j+1;
end

if(detector_filtrado2011_rodgen_de_preceptron(k)==0)&(detector_filtrado2011_rodgen_de_rbf(k)>0)&(detector_filtrado2011_rodgen_de_svm(k)>0)
    detector(k)=2;

fecha2011_anomalias_rodgen_de(j,1)=filtrado2011_fecha_conv(k,1);
fecha2011_anomalias_rodgen_de(j,2)=filtrado2011_fecha_conv(k,2);
fecha2011_anomalias_rodgen_de(j,3)=filtrado2011_fecha_conv(k,3);
fecha2011_anomalias_rodgen_de(j,4)=filtrado2011_fecha_conv(k,4);
fecha2011_anomalias_rodgen_de(j,5)=filtrado2011_fecha_conv(k,5);
fecha2011_anomalias_rodgen_de(j,6)=filtrado2011_fecha_conv(k,6);
    j=j+1;
end

if(detector_filtrado2011_rodgen_de_preceptron(k)==0)&(detector_filtrado2011_rodgen_de_rbf(k)==0)&(detector_filtrado2011_rodgen_de_svm(k)>0)
    detector(k)=1;
end

if(detector_filtrado2011_rodgen_de_preceptron(k)==0)&(detector_filtrado2011_rodgen_de_rbf(k)>0)&(detector_filtrado2011_rodgen_de_svm(k)==0)
    detector(k)=1;
end

if(detector_filtrado2011_rodgen_de_preceptron(k)>0)&(detector_filtrado2011_rodgen_de_rbf(k)==0)&(detector_filtrado2011_rodgen_de_svm(k)==0)
    detector(k)=1;
end

if(detector_filtrado2011_rodgen_de_preceptron(k)==0)&(detector_filtrado2011_rodgen_de_rbf(k)==0)&(detector_filtrado2011_rodgen_de_svm(k)==0)
    detector(k)=0;
end
end

figure(2)
plot(1:n, detector);

detectortotal_2011_rodgen_de=detector;

```

-Rodamiento NDE del generador:

```

clear all
close all
clc

```

```

load('detector_filtrado2011_rodgen_nde_preceptron.mat');
load('detector_filtrado2011_rodgen_nde_rbf.mat');

```

```

load('detector_filtrado2011_rodgen_nde_svm.mat');
load('filtrado2011_fecha_conv');

[m n]=size(detector_filtrado2011_rodgen_nde_preceptron);

figure(1)
plot(1:n, detector_filtrado2011_rodgen_nde_preceptron, 'b', 1:n,
detector_filtrado2011_rodgen_nde_rbf, 'g', 1:n, detector_filtrado2011_rod
gen_nde_svm, 'r');
legend('alarma perceptron', 'alarma RBF', 'alarma SVM')
j=1;

for k=1:n;

if(detector_filtrado2011_rodgen_nde_preceptron(k)>0)&(detector_filtrad
o2011_rodgen_nde_rbf(k)>0)&(detector_filtrado2011_rodgen_nde_svm(k)>0)
    detector(k)=3;

    fecha2011_anomalias_rodgen_nde(j,1)=filtrado2011_fecha_conv(k,1);
    fecha2011_anomalias_rodgen_nde(j,2)=filtrado2011_fecha_conv(k,2);
    fecha2011_anomalias_rodgen_nde(j,3)=filtrado2011_fecha_conv(k,3);
    fecha2011_anomalias_rodgen_nde(j,4)=filtrado2011_fecha_conv(k,4);
    fecha2011_anomalias_rodgen_nde(j,5)=filtrado2011_fecha_conv(k,5);
    fecha2011_anomalias_rodgen_nde(j,6)=filtrado2011_fecha_conv(k,6);
    j=j+1;
end

if(detector_filtrado2011_rodgen_nde_preceptron(k)>0)&(detector_filtrad
o2011_rodgen_nde_rbf(k)>0)&(detector_filtrado2011_rodgen_nde_svm(k)==0
)
    detector(k)=2;

    fecha2011_anomalias_rodgen_nde(j,1)=filtrado2011_fecha_conv(k,1);
    fecha2011_anomalias_rodgen_nde(j,2)=filtrado2011_fecha_conv(k,2);
    fecha2011_anomalias_rodgen_nde(j,3)=filtrado2011_fecha_conv(k,3);
    fecha2011_anomalias_rodgen_nde(j,4)=filtrado2011_fecha_conv(k,4);
    fecha2011_anomalias_rodgen_nde(j,5)=filtrado2011_fecha_conv(k,5);
    fecha2011_anomalias_rodgen_nde(j,6)=filtrado2011_fecha_conv(k,6);
    j=j+1;
end

if(detector_filtrado2011_rodgen_nde_preceptron(k)>0)&(detector_filtrad
o2011_rodgen_nde_rbf(k)==0)&(detector_filtrado2011_rodgen_nde_svm(k)>0
)
    detector(k)=2;

    fecha2011_anomalias_rodgen_nde(j,1)=filtrado2011_fecha_conv(k,1);
    fecha2011_anomalias_rodgen_nde(j,2)=filtrado2011_fecha_conv(k,2);
    fecha2011_anomalias_rodgen_nde(j,3)=filtrado2011_fecha_conv(k,3);

```

```

fecha2011_anomalias_rodgen_nde(j,4)=filtrado2011_fecha_conv(k,4);
fecha2011_anomalias_rodgen_nde(j,5)=filtrado2011_fecha_conv(k,5);
fecha2011_anomalias_rodgen_nde(j,6)=filtrado2011_fecha_conv(k,6);
    j=j+1;
end

if(detector_filtrado2011_rodgen_nde_preceptron(k)==0)&(detector_filtrado2011_rodgen_nde_rbf(k)>0)&(detector_filtrado2011_rodgen_nde_svm(k)>0)
    detector(k)=2;

fecha2011_anomalias_rodgen_nde(j,1)=filtrado2011_fecha_conv(k,1);
fecha2011_anomalias_rodgen_nde(j,2)=filtrado2011_fecha_conv(k,2);
fecha2011_anomalias_rodgen_nde(j,3)=filtrado2011_fecha_conv(k,3);
fecha2011_anomalias_rodgen_nde(j,4)=filtrado2011_fecha_conv(k,4);
fecha2011_anomalias_rodgen_nde(j,5)=filtrado2011_fecha_conv(k,5);
fecha2011_anomalias_rodgen_nde(j,6)=filtrado2011_fecha_conv(k,6);
    j=j+1;
end

if(detector_filtrado2011_rodgen_nde_preceptron(k)==0)&(detector_filtrado2011_rodgen_nde_rbf(k)==0)&(detector_filtrado2011_rodgen_nde_svm(k)>0)
    detector(k)=1;
end

if(detector_filtrado2011_rodgen_nde_preceptron(k)==0)&(detector_filtrado2011_rodgen_nde_rbf(k)>0)&(detector_filtrado2011_rodgen_nde_svm(k)==0)
    detector(k)=1;
end

if(detector_filtrado2011_rodgen_nde_preceptron(k)>0)&(detector_filtrado2011_rodgen_nde_rbf(k)==0)&(detector_filtrado2011_rodgen_nde_svm(k)==0)
    detector(k)=1;
end

if(detector_filtrado2011_rodgen_nde_preceptron(k)==0)&(detector_filtrado2011_rodgen_nde_rbf(k)==0)&(detector_filtrado2011_rodgen_nde_svm(k)==0)
    detector(k)=0;
end
end

figure(2)
plot(1:n, detector);

detectortotal_2011_rodgen_nde=detector;

```

-Rodamiento de la multiplicadora:

```
clear all
close all
clc

load('detector_filtrado2011_rodmulti_preceptron.mat');
load('detector_filtrado2011_rodmulti_rbf.mat');
load('detector_filtrado2011_rodmulti_svm.mat');
load('filtrado2011_fecha_conv');

[m n]=size(detector_filtrado2011_rodmulti_preceptron);

figure(1)
plot(1:n, detector_filtrado2011_rodmulti_preceptron, 'b', 1:n,
detector_filtrado2011_rodmulti_rbf, 'g', 1:n, detector_filtrado2011_rodmu
lti_svm, 'r');
legend('alarma perceptron', 'alarma RBF', 'alarma SVM')
j=1;

for k=1:n;

if(detector_filtrado2011_rodmulti_preceptron(k)>0)&(detector_filtrado2
011_rodmulti_rbf(k)>0)&(detector_filtrado2011_rodmulti_svm(k)>0)
    detector(k)=3;
    fecha2011_anomalias_rodmulti(j,1)=filtrado2011_fecha_conv(k,1);
    fecha2011_anomalias_rodmulti(j,2)=filtrado2011_fecha_conv(k,2);
    fecha2011_anomalias_rodmulti(j,3)=filtrado2011_fecha_conv(k,3);
    fecha2011_anomalias_rodmulti(j,4)=filtrado2011_fecha_conv(k,4);
    fecha2011_anomalias_rodmulti(j,5)=filtrado2011_fecha_conv(k,5);
    fecha2011_anomalias_rodmulti(j,6)=filtrado2011_fecha_conv(k,6);
    j=j+1;
end

if(detector_filtrado2011_rodmulti_preceptron(k)>0)&(detector_filtrado2
011_rodmulti_rbf(k)>0)&(detector_filtrado2011_rodmulti_svm(k)==0)
    detector(k)=2;
    fecha2011_anomalias_rodmulti(j,1)=filtrado2011_fecha_conv(k,1);
    fecha2011_anomalias_rodmulti(j,2)=filtrado2011_fecha_conv(k,2);
    fecha2011_anomalias_rodmulti(j,3)=filtrado2011_fecha_conv(k,3);
    fecha2011_anomalias_rodmulti(j,4)=filtrado2011_fecha_conv(k,4);
    fecha2011_anomalias_rodmulti(j,5)=filtrado2011_fecha_conv(k,5);
    fecha2011_anomalias_rodmulti(j,6)=filtrado2011_fecha_conv(k,6);
    j=j+1;
end

if(detector_filtrado2011_rodmulti_preceptron(k)>0)&(detector_filtrado2
011_rodmulti_rbf(k)==0)&(detector_filtrado2011_rodmulti_svm(k)>0)
    detector(k)=2;
    fecha2011_anomalias_rodmulti(j,1)=filtrado2011_fecha_conv(k,1);
    fecha2011_anomalias_rodmulti(j,2)=filtrado2011_fecha_conv(k,2);
    fecha2011_anomalias_rodmulti(j,3)=filtrado2011_fecha_conv(k,3);
    fecha2011_anomalias_rodmulti(j,4)=filtrado2011_fecha_conv(k,4);
    fecha2011_anomalias_rodmulti(j,5)=filtrado2011_fecha_conv(k,5);
    fecha2011_anomalias_rodmulti(j,6)=filtrado2011_fecha_conv(k,6);
    j=j+1;
end
```

```

if(detector_filtrado2011_rodmulti_preceptron(k)==0)&(detector_filtrado
2011_rodmulti_rbf(k)>0)&(detector_filtrado2011_rodmulti_svm(k)>0)
    detector(k)=2;
    fecha2011_anomalias_rodmulti(j,1)=filtrado2011_fecha_conv(k,1);
    fecha2011_anomalias_rodmulti(j,2)=filtrado2011_fecha_conv(k,2);
    fecha2011_anomalias_rodmulti(j,3)=filtrado2011_fecha_conv(k,3);
    fecha2011_anomalias_rodmulti(j,4)=filtrado2011_fecha_conv(k,4);
    fecha2011_anomalias_rodmulti(j,5)=filtrado2011_fecha_conv(k,5);
    fecha2011_anomalias_rodmulti(j,6)=filtrado2011_fecha_conv(k,6);
    j=j+1;
end

if(detector_filtrado2011_rodmulti_preceptron(k)==0)&(detector_filtrado
2011_rodmulti_rbf(k)==0)&(detector_filtrado2011_rodmulti_svm(k)>0)
    detector(k)=1;
end

if(detector_filtrado2011_rodmulti_preceptron(k)==0)&(detector_filtrado
2011_rodmulti_rbf(k)>0)&(detector_filtrado2011_rodmulti_svm(k)==0)
    detector(k)=1;
end

if(detector_filtrado2011_rodmulti_preceptron(k)>0)&(detector_filtrado2
011_rodmulti_rbf(k)==0)&(detector_filtrado2011_rodmulti_svm(k)==0)
    detector(k)=1;
end

if(detector_filtrado2011_rodmulti_preceptron(k)==0)&(detector_filtrado
2011_rodmulti_rbf(k)==0)&(detector_filtrado2011_rodmulti_svm(k)==0)
    detector(k)=0;
end
end

figure(2)
plot(1:n, detector);

detectortotal_2011_rodmulti=detector;

```

Anexo IX – Códigos para realizar el indicador de salud – N° de anomalías por día

-Aceite de la multiplicadora:

```
clear all
close all
clc

load('dias_conv.mat');
load('fecha2011_anomalias_aceite_multi.mat')
load('fecha2012_anomalias_aceite_multi.mat')
load('fecha2013_anomalias_aceite_multi.mat')
load('fecha2014_anomalias_aceite_multi.mat')

[n1 m]=size(fecha2011_anomalias_aceite_multi);
[n2 m]=size(fecha2012_anomalias_aceite_multi);
[n3 m]=size(fecha2013_anomalias_aceite_multi);
[n4 m]=size(fecha2014_anomalias_aceite_multi);

[n_fechas m]=size(dias_conv);

for k=1:n_fechas
    if(k<=365)
        c=0; %contador de anomalias
        for l=1:n1

            if(fecha2011_anomalias_aceite_multi(l,1)==dias_conv(k,1))&(fecha2011_a
nomalias_aceite_multi(l,2)==dias_conv(k,2))
                c=c+1;
            end
        end
        indicador_aceite_multi(k)=c;
    end
    if(k>365)&(k<=731)
        c=0; %contador de anomalias
        for l=1:n2

            if(fecha2012_anomalias_aceite_multi(l,1)==dias_conv(k,1))&(fecha2012_a
nomalias_aceite_multi(l,2)==dias_conv(k,2))
                c=c+1;
            end
        end
        indicador_aceite_multi(k)=c;
    end
    if(k>731)&(k<=1096)
        c=0; %contador de anomalias
        for l=1:n3

            if(fecha2013_anomalias_aceite_multi(l,1)==dias_conv(k,1))&(fecha2013_a
nomalias_aceite_multi(l,2)==dias_conv(k,2))
                c=c+1;
            end
        end
        indicador_aceite_multi(k)=c;
    end
end
```

```

        if(k>1096)
            c=0; %contador de anomalias
            for l=1:n4

if(fecha2014_anomalias_aceite_multi(l,1)==dias_conv(k,1))&(fecha2014_a
nomalias_aceite_multi(l,2)==dias_conv(k,2))
                c=c+1;
            end
        end
        indicador_aceite_multi(k)=c;
    end
end

indicador2011_mensual=zeros(1,12);
indicador2012_mensual=zeros(1,12);
indicador2013_mensual=zeros(1,12);
indicador2014_mensual=zeros(1,9);
i=1;
for k=1:365
    if(dias_conv(k,2)==i)

indicador2011_mensual(i)=indicador2011_mensual(i)+indicador_aceite_mul
ti(k);
        end
        if(dias_conv(k,2)>i)
            i=i+1;

indicador2011_mensual(i)=indicador2011_mensual(i)+indicador_aceite_mul
ti(k);
        end
    end
    i=1;
    for k=366:731
        if(dias_conv(k,2)==i)

indicador2012_mensual(i)=indicador2012_mensual(i)+indicador_aceite_mul
ti(k);
            end
            if(dias_conv(k,2)>i)
                i=i+1;

indicador2012_mensual(i)=indicador2012_mensual(i)+indicador_aceite_mul
ti(k);
            end
        end
        i=1;
        for k=732:1096
            if(dias_conv(k,2)==i)

indicador2013_mensual(i)=indicador2013_mensual(i)+indicador_aceite_mul
ti(k);
                end
                if(dias_conv(k,2)>i)
                    i=i+1;

indicador2013_mensual(i)=indicador2013_mensual(i)+indicador_aceite_mul
ti(k);
                end
            end
            i=1;
            for k=1097:1277

```

```

        if(dias_conv(k,2)==i)

indicador2014_mensual(i)=indicador2014_mensual(i)+indicador_aceite_multi(k);
        end
        if(dias_conv(k,2)>i)
            i=i+1;

indicador2014_mensual(i)=indicador2014_mensual(i)+indicador_aceite_multi(k);
        end
    end
    indicador_anual(1)=mean(indicador2011_mensual);
    indicador_anual(2)=mean(indicador2012_mensual);
    indicador_anual(3)=mean(indicador2013_mensual);
    indicador_anual(4)=mean(indicador2014_mensual);

    plot([365 365], [0, max(indicador_aceite_multi)], 'k', [731 731], [0,
max(indicador_aceite_multi)], 'k', [1096 1096], [0,
max(indicador_aceite_multi)], 'k')

    hold on
    plot(1:n_fechas, indicador_aceite_multi);
    ylabel('Anomalies'); xlabel('Time');

```

-Anillos del generador

```

clear all
close all
clc

load('dias_conv.mat');
load('fecha2011_anomalias_anillosgen.mat')
load('fecha2012_anomalias_anillosgen.mat')
load('fecha2013_anomalias_anillosgen.mat')
load('fecha2014_anomalias_anillosgen.mat')

[n1 m]=size(fecha2011_anomalias_anillosgen);
[n2 m]=size(fecha2012_anomalias_anillosgen);
[n3 m]=size(fecha2013_anomalias_anillosgen);
[n4 m]=size(fecha2014_anomalias_anillosgen);

[n_fechas m]=size(dias_conv);

for k=1:n_fechas
    if(k<=365)
        c=0; %contador de anomalias
        for l=1:n1

            if(fecha2011_anomalias_anillosgen(l,1)==dias_conv(k,1))&(fecha2011_anomalias_anillosgen(l,2)==dias_conv(k,2))
                c=c+1;
            end
        end
        indicador_anillosgen(k)=c;
    end
end

```

```

        if(k>365)&(k<=731)
            c=0; %contador de anomalias
            for l=1:n2

                if(fecha2012_anomalias_anillosgen(l,1)==dias_conv(k,1))&(fecha2012_anomalias_anillosgen(l,2)==dias_conv(k,2))
                    c=c+1;
                end
            end
            indicador_anillosgen(k)=c;
        end
        if(k>731)&(k<=1096)
            c=0; %contador de anomalias
            for l=1:n3

                if(fecha2013_anomalias_anillosgen(l,1)==dias_conv(k,1))&(fecha2013_anomalias_anillosgen(l,2)==dias_conv(k,2))
                    c=c+1;
                end
            end
            indicador_anillosgen(k)=c;
        end
        if(k>1096)
            c=0; %contador de anomalias
            for l=1:n4

                if(fecha2014_anomalias_anillosgen(l,1)==dias_conv(k,1))&(fecha2014_anomalias_anillosgen(l,2)==dias_conv(k,2))
                    c=c+1;
                end
            end
            indicador_anillosgen(k)=c;
        end
    end

    indicador2011_mensual=zeros(1,12);
    indicador2012_mensual=zeros(1,12);
    indicador2013_mensual=zeros(1,12);
    indicador2014_mensual=zeros(1,9);
    i=1;
    for k=1:365
        if(dias_conv(k,2)==i)

            indicador2011_mensual(i)=indicador2011_mensual(i)+indicador_anillosgen(k);
        end
        if(dias_conv(k,2)>i)
            i=i+1;

            indicador2011_mensual(i)=indicador2011_mensual(i)+indicador_anillosgen(k);
        end
    end
    i=1;
    for k=366:731
        if(dias_conv(k,2)==i)

            indicador2012_mensual(i)=indicador2012_mensual(i)+indicador_anillosgen(k);
        end
        if(dias_conv(k,2)>i)

```

```

        i=i+1;

indicador2012_mensual(i)=indicador2012_mensual(i)+indicador_anillosgen
(k);
    end
end
i=1;
for k=732:1096
    if(dias_conv(k,2)==i)

indicador2013_mensual(i)=indicador2013_mensual(i)+indicador_anillosgen
(k);
        end
        if(dias_conv(k,2)>i)
            i=i+1;

indicador2013_mensual(i)=indicador2013_mensual(i)+indicador_anillosgen
(k);
            end
            end
i=1;
for k=1097:1277
    if(dias_conv(k,2)==i)

indicador2014_mensual(i)=indicador2014_mensual(i)+indicador_anillosgen
(k);
        end
        if(dias_conv(k,2)>i)
            i=i+1;

indicador2014_mensual(i)=indicador2014_mensual(i)+indicador_anillosgen
(k);
            end
            end
end

indicador_anual(1)=mean(indicador2011_mensual);
indicador_anual(2)=mean(indicador2012_mensual);
indicador_anual(3)=mean(indicador2013_mensual);
indicador_anual(4)=mean(indicador2014_mensual);

plot([365 365], [0, max(indicador_anillosgen)], 'k', [731 731], [0,
max(indicador_anillosgen)], 'k', [1096 1096], [0,
max(indicador_anillosgen)], 'k')
hold on
plot(1:n_fechas, indicador_anillosgen);
ylabel('Anomalies'); xlabel('Time');

```

-Rodamiento DE del generador

```

clear all
close all
clc

load('dias_conv.mat');
load('fecha2011_anomalias_rodgen_de.mat')
load('fecha2012_anomalias_rodgen_de.mat')
load('fecha2013_anomalias_rodgen_de.mat')
load('fecha2014_anomalias_rodgen_de.mat')

```

```

[n1 m]=size(fecha2011_anomalias_rodgen_de);
[n2 m]=size(fecha2012_anomalias_rodgen_de);
[n3 m]=size(fecha2013_anomalias_rodgen_de);
[n4 m]=size(fecha2014_anomalias_rodgen_de);

[n_fechas m]=size(dias_conv);

for k=1:n_fechas
    if(k<=365)
        c=0; %contador de anomalias
        for l=1:n1

            if(fecha2011_anomalias_rodgen_de(l,1)==dias_conv(k,1))&(fecha2011_anom
alias_rodgen_de(l,2)==dias_conv(k,2))
                c=c+1;
            end
        end
        indicador_rodgen_de(k)=c;
    end
    if(k>365)&(k<=731)
        c=0; %contador de anomalias
        for l=1:n2

            if(fecha2012_anomalias_rodgen_de(l,1)==dias_conv(k,1))&(fecha2012_anom
alias_rodgen_de(l,2)==dias_conv(k,2))
                c=c+1;
            end
        end
        indicador_rodgen_de(k)=c;
    end
    if(k>731)&(k<=1096)
        c=0; %contador de anomalias
        for l=1:n3

            if(fecha2013_anomalias_rodgen_de(l,1)==dias_conv(k,1))&(fecha2013_anom
alias_rodgen_de(l,2)==dias_conv(k,2))
                c=c+1;
            end
        end
        indicador_rodgen_de(k)=c;
    end
    if(k>1096)
        c=0; %contador de anomalias
        for l=1:n4

            if(fecha2014_anomalias_rodgen_de(l,1)==dias_conv(k,1))&(fecha2014_anom
alias_rodgen_de(l,2)==dias_conv(k,2))
                c=c+1;
            end
        end
        indicador_rodgen_de(k)=c;
    end
end

indicador2011_mensual=zeros(1,12);
indicador2012_mensual=zeros(1,12);
indicador2013_mensual=zeros(1,12);

```

```

indicador2014_mensual=zeros(1,9);
i=1;
for k=1:365
    if(dias_conv(k,2)==i)

indicador2011_mensual(i)=indicador2011_mensual(i)+indicador_rodgen_de(
k);
        end
        if(dias_conv(k,2)>i)
            i=i+1;

indicador2011_mensual(i)=indicador2011_mensual(i)+indicador_rodgen_de(
k);
        end
    end
i=1;
for k=366:731
    if(dias_conv(k,2)==i)

indicador2012_mensual(i)=indicador2012_mensual(i)+indicador_rodgen_de(
k);
        end
        if(dias_conv(k,2)>i)
            i=i+1;

indicador2012_mensual(i)=indicador2012_mensual(i)+indicador_rodgen_de(
k);
        end
    end
i=1;
for k=732:1096
    if(dias_conv(k,2)==i)

indicador2013_mensual(i)=indicador2013_mensual(i)+indicador_rodgen_de(
k);
        end
        if(dias_conv(k,2)>i)
            i=i+1;

indicador2013_mensual(i)=indicador2013_mensual(i)+indicador_rodgen_de(
k);
        end
    end
i=1;
for k=1097:1277
    if(dias_conv(k,2)==i)

indicador2014_mensual(i)=indicador2014_mensual(i)+indicador_rodgen_de(
k);
        end
        if(dias_conv(k,2)>i)
            i=i+1;

indicador2014_mensual(i)=indicador2014_mensual(i)+indicador_rodgen_de(
k);
        end
    end

indicador_anual(1)=mean(indicador2011_mensual);
indicador_anual(2)=mean(indicador2012_mensual);
indicador_anual(3)=mean(indicador2013_mensual);

```

```

indicador_anual(4)=mean(indicador2014_mensual);

plot([365 365], [0, max(indicador_rodgen_de)], 'k', [731 731], [0,
max(indicador_rodgen_de)], 'k', [1096 1096], [0,
max(indicador_rodgen_de)], 'k')

hold on
plot(1:n_fechas, indicador_rodgen_de);
ylabel('Anomalies'); xlabel('Time');

```

-Rodamiento NDE del generador:

```

clear all
close all
clc

load('dias_conv.mat');
load('fecha2011_anomalias_rodgen_nde.mat')
load('fecha2012_anomalias_rodgen_nde.mat')
load('fecha2013_anomalias_rodgen_nde.mat')
load('fecha2014_anomalias_rodgen_nde.mat')

[n1 m]=size(fecha2011_anomalias_rodgen_nde);
[n2 m]=size(fecha2012_anomalias_rodgen_nde);
[n3 m]=size(fecha2013_anomalias_rodgen_nde);
[n4 m]=size(fecha2014_anomalias_rodgen_nde);

[n_fechas m]=size(dias_conv);

for k=1:n_fechas
    if(k<=365)
        c=0; %contador de anomalias
        for l=1:n1

            if(fecha2011_anomalias_rodgen_nde(l,1)==dias_conv(k,1))&(fecha2011_anomalias_rodgen_nde(l,2)==dias_conv(k,2))
                c=c+1;
            end
        end
        indicador_rodgen_nde(k)=c;
    end
    if(k>365)&(k<=731)
        c=0; %contador de anomalias
        for l=1:n2

            if(fecha2012_anomalias_rodgen_nde(l,1)==dias_conv(k,1))&(fecha2012_anomalias_rodgen_nde(l,2)==dias_conv(k,2))
                c=c+1;
            end
        end
        indicador_rodgen_nde(k)=c;
    end
end

```

```

        if(k>731)&(k<=1096)
            c=0; %contador de anomalias
            for l=1:n3

if(fecha2013_anomalias_rodgen_nde(l,1)==dias_conv(k,1))&(fecha2013_anomalias_rodgen_nde(l,2)==dias_conv(k,2))
                c=c+1;
            end
            end
            indicador_rodgen_nde(k)=c;
        end
        if(k>1096)
            c=0; %contador de anomalias
            for l=1:n4

if(fecha2014_anomalias_rodgen_nde(l,1)==dias_conv(k,1))&(fecha2014_anomalias_rodgen_nde(l,2)==dias_conv(k,2))
                c=c+1;
            end
            end
            indicador_rodgen_nde(k)=c;
        end
    end

    indicador2011_mensual=zeros(1,12);
    indicador2012_mensual=zeros(1,12);
    indicador2013_mensual=zeros(1,12);
    indicador2014_mensual=zeros(1,9);
    i=1;
    for k=1:365
        if(dias_conv(k,2)==i)

            indicador2011_mensual(i)=indicador2011_mensual(i)+indicador_rodgen_nde(k);
            end
            if(dias_conv(k,2)>i)
                i=i+1;

            indicador2011_mensual(i)=indicador2011_mensual(i)+indicador_rodgen_nde(k);
            end
        end
        i=1;
        for k=366:731
            if(dias_conv(k,2)==i)

            indicador2012_mensual(i)=indicador2012_mensual(i)+indicador_rodgen_nde(k);
            end
            if(dias_conv(k,2)>i)
                i=i+1;

            indicador2012_mensual(i)=indicador2012_mensual(i)+indicador_rodgen_nde(k);
            end
        end
        i=1;
        for k=732:1096
            if(dias_conv(k,2)==i)

```

```

indicador2013_mensual(i)=indicador2013_mensual(i)+indicador_rodgen_nde
(k);
    end
    if(dias_conv(k,2)>i)
        i=i+1;

indicador2013_mensual(i)=indicador2013_mensual(i)+indicador_rodgen_nde
(k);
    end
end
i=1;
for k=1097:1277
    if(dias_conv(k,2)==i)

indicador2014_mensual(i)=indicador2014_mensual(i)+indicador_rodgen_nde
(k);
        end
        if(dias_conv(k,2)>i)
            i=i+1;

indicador2014_mensual(i)=indicador2014_mensual(i)+indicador_rodgen_nde
(k);
        end
end

indicador_anual(1)=mean(indicador2011_mensual);
indicador_anual(2)=mean(indicador2012_mensual);
indicador_anual(3)=mean(indicador2013_mensual);
indicador_anual(4)=mean(indicador2014_mensual);

plot([365 365], [0, max(indicador_rodgen_nde)], 'k', [731 731], [0,
max(indicador_rodgen_nde)], 'k', [1096 1096], [0,
max(indicador_rodgen_nde)], 'k')

hold on
plot(1:n_fechas, indicador_rodgen_nde);
ylabel('Anomalies'); xlabel('Time');

```

-Rodamiento de la multiplicadora:

```

clear all
close all
clc

load('dias_conv.mat');
load('fecha2011_anomalias_rodmulti.mat')
load('fecha2012_anomalias_rodmulti.mat')
load('fecha2013_anomalias_rodmulti.mat')
load('fecha2014_anomalias_rodmulti.mat')

[n1 m]=size(fecha2011_anomalias_rodmulti);
[n2 m]=size(fecha2012_anomalias_rodmulti);
[n3 m]=size(fecha2013_anomalias_rodmulti);
[n4 m]=size(fecha2014_anomalias_rodmulti);

```

```

[n_fechas m]=size(dias_conv);

for k=1:n_fechas
    if(k<=365)
        c=0; %contador de anomalias
        for l=1:n1

            if(fecha2011_anomalias_rodmulti(l,1)==dias_conv(k,1))&(fecha2011_anomalias_rodmulti(l,2)==dias_conv(k,2))
                c=c+1;
            end
        end
        indicador_rodmulti(k)=c;
    end
    if(k>365)&(k<=731)
        c=0; %contador de anomalias
        for l=1:n2

            if(fecha2012_anomalias_rodmulti(l,1)==dias_conv(k,1))&(fecha2012_anomalias_rodmulti(l,2)==dias_conv(k,2))
                c=c+1;
            end
        end
        indicador_rodmulti(k)=c;
    end
    if(k>731)&(k<=1096)
        c=0; %contador de anomalias
        for l=1:n3

            if(fecha2013_anomalias_rodmulti(l,1)==dias_conv(k,1))&(fecha2013_anomalias_rodmulti(l,2)==dias_conv(k,2))
                c=c+1;
            end
        end
        indicador_rodmulti(k)=c;
    end
    if(k>1096)
        c=0; %contador de anomalias
        for l=1:n4

            if(fecha2014_anomalias_rodmulti(l,1)==dias_conv(k,1))&(fecha2014_anomalias_rodmulti(l,2)==dias_conv(k,2))
                c=c+1;
            end
        end
        indicador_rodmulti(k)=c;
    end
end

indicador2011_mensual=zeros(1,12);
indicador2012_mensual=zeros(1,12);
indicador2013_mensual=zeros(1,12);
indicador2014_mensual=zeros(1,9);
i=1;
for k=1:365
    if(dias_conv(k,2)==i)

        indicador2011_mensual(i)=indicador2011_mensual(i)+indicador_rodmulti(k);
    end
end

```

```

        if(dias_conv(k,2)>i)
            i=i+1;

indicador2011_mensual(i)=indicador2011_mensual(i)+indicador_rodmulti(k
);
    end
end
i=1;
for k=366:731
    if(dias_conv(k,2)==i)

indicador2012_mensual(i)=indicador2012_mensual(i)+indicador_rodmulti(k
);
        end
        if(dias_conv(k,2)>i)
            i=i+1;

indicador2012_mensual(i)=indicador2012_mensual(i)+indicador_rodmulti(k
);
        end
    end
i=1;
for k=732:1096
    if(dias_conv(k,2)==i)

indicador2013_mensual(i)=indicador2013_mensual(i)+indicador_rodmulti(k
);
        end
        if(dias_conv(k,2)>i)
            i=i+1;

indicador2013_mensual(i)=indicador2013_mensual(i)+indicador_rodmulti(k
);
        end
    end
i=1;
for k=1097:1277
    if(dias_conv(k,2)==i)

indicador2014_mensual(i)=indicador2014_mensual(i)+indicador_rodmulti(k
);
        end
        if(dias_conv(k,2)>i)
            i=i+1;

indicador2014_mensual(i)=indicador2014_mensual(i)+indicador_rodmulti(k
);
        end
    end

indicador_anual(1)=mean(indicador2011_mensual);
indicador_anual(2)=mean(indicador2012_mensual);
indicador_anual(3)=mean(indicador2013_mensual);
indicador_anual(4)=mean(indicador2014_mensual);

plot([365 365], [0, max(indicador_rodmulti)], 'k', [731 731], [0,
max(indicador_rodmulti)], 'k', [1096 1096], [0,
max(indicador_rodmulti)], 'k')

hold on
plot(1:n_fechas, indicador_rodmulti);

```

```
ylabel('Anomalies'); xlabel('Time');
```

-Generador:

```
clear all  
close all  
clc
```

```
load('dias_conv.mat');  
load('indicador_anillosgen.mat')  
load('indicador_rodgen_de.mat')  
load('indicador_rodgen_nde.mat')
```

```
[m n]=size(indicador_anillosgen);
```

```
for k=1:n
```

```
    indicador_generador(k)=indicador_anillosgen(k)+indicador_rodgen_de(k)+  
    indicador_rodgen_nde(k);
```

```
end
```

```
indicador2011_mensual=zeros(1,12);  
indicador2012_mensual=zeros(1,12);  
indicador2013_mensual=zeros(1,12);  
indicador2014_mensual=zeros(1,9);  
i=1;
```

```
for k=1:365  
    if(dias_conv(k,2)==i)
```

```
        indicador2011_mensual(i)=indicador2011_mensual(i)+indicador_generador(  
k);
```

```
        end  
        if(dias_conv(k,2)>i)  
            i=i+1;
```

```
        indicador2011_mensual(i)=indicador2011_mensual(i)+indicador_generador(  
k);
```

```
        end
```

```
end
```

```
i=1;
```

```
for k=366:731  
    if(dias_conv(k,2)==i)
```

```
        indicador2012_mensual(i)=indicador2012_mensual(i)+indicador_generador(  
k);
```

```
        end  
        if(dias_conv(k,2)>i)  
            i=i+1;
```

```
        indicador2012_mensual(i)=indicador2012_mensual(i)+indicador_generador(  
k);
```

```
        end
```

```
end
```

```

i=1;
for k=732:1096
    if(dias_conv(k,2)==i)

indicador2013_mensual(i)=indicador2013_mensual(i)+indicador_generador(
k);
        end
        if(dias_conv(k,2)>i)
            i=i+1;

indicador2013_mensual(i)=indicador2013_mensual(i)+indicador_generador(
k);
        end
    end
i=1;
for k=1097:1277
    if(dias_conv(k,2)==i)

indicador2014_mensual(i)=indicador2014_mensual(i)+indicador_generador(
k);
        end
        if(dias_conv(k,2)>i)
            i=i+1;

indicador2014_mensual(i)=indicador2014_mensual(i)+indicador_generador(
k);
        end
    end

indicador_anual(1)=mean(indicador2011_mensual);
indicador_anual(2)=mean(indicador2012_mensual);
indicador_anual(3)=mean(indicador2013_mensual);
indicador_anual(4)=mean(indicador2014_mensual);

plot([365 365], [0, max(indicador_generador)], 'k', [731 731], [0,
max(indicador_generador)], 'k', [1096 1096], [0,
max(indicador_generador)], 'k')

hold on
plot(1:n, indicador_generador);
ylabel('Anomalies'); xlabel('Time');

```

-Multiplicadora:

```

clear all
close all
clc

load('dias_conv.mat');
load('indicador_aceite_multi.mat')
load('indicador_rodmulti.mat')

[m n]=size(indicador_aceite_multi);

```

```

for k=1:n

indicador_multi(k)=indicador_aceite_multi(k)+indicador_rodmulti(k);

end

indicador2011_mensual=zeros(1,12);
indicador2012_mensual=zeros(1,12);
indicador2013_mensual=zeros(1,12);
indicador2014_mensual=zeros(1,9);
i=1;
for k=1:365
    if(dias_conv(k,2)==i)

indicador2011_mensual(i)=indicador2011_mensual(i)+indicador_multi(k);
        end
        if(dias_conv(k,2)>i)
            i=i+1;

indicador2011_mensual(i)=indicador2011_mensual(i)+indicador_multi(k);
        end
    end
    i=1;
    for k=366:731
        if(dias_conv(k,2)==i)

indicador2012_mensual(i)=indicador2012_mensual(i)+indicador_multi(k);
                end
                if(dias_conv(k,2)>i)
                    i=i+1;

indicador2012_mensual(i)=indicador2012_mensual(i)+indicador_multi(k);
                end
            end
            i=1;
            for k=732:1096
                if(dias_conv(k,2)==i)

indicador2013_mensual(i)=indicador2013_mensual(i)+indicador_multi(k);
                        end
                        if(dias_conv(k,2)>i)
                            i=i+1;

indicador2013_mensual(i)=indicador2013_mensual(i)+indicador_multi(k);
                        end
                    end
                    i=1;
                    for k=1097:1277
                        if(dias_conv(k,2)==i)

indicador2014_mensual(i)=indicador2014_mensual(i)+indicador_multi(k);
                                end
                                if(dias_conv(k,2)>i)
                                    i=i+1;

indicador2014_mensual(i)=indicador2014_mensual(i)+indicador_multi(k);
                                end
                            end
                        end

indicador_anual(1)=mean(indicador2011_mensual);
indicador_anual(2)=mean(indicador2012_mensual);

```

```

indicador_anual(3)=mean(indicador2013_mensual);
indicador_anual(4)=mean(indicador2014_mensual);

plot([365 365], [0, max(indicador_multi)], 'k', [731 731], [0,
max(indicador_multi)], 'k', [1096 1096], [0, max(indicador_multi)], 'k')

hold on
plot(1:n, indicador_multi);
ylabel('Anomalies'); xlabel('Time');

```

-Paso de palas:

```

clear all
close all
clc

load('dias_conv.mat');
load('fecha2011_anomalias_pasopalas.mat')
load('fecha2012_anomalias_pasopalas.mat')
load('fecha2013_anomalias_pasopalas.mat')
load('fecha2014_anomalias_pasopalas.mat')

[n1 m]=size(fecha2011_anomalias_pasopalas);
[n2 m]=size(fecha2012_anomalias_pasopalas);
[n3 m]=size(fecha2013_anomalias_pasopalas);
[n4 m]=size(fecha2014_anomalias_pasopalas);

[n_fechas m]=size(dias_conv);

for k=1:n_fechas
    if(k<=365)
        c=0; %contador de anomalias
        for l=1:n1

            if(fecha2011_anomalias_pasopalas(l,1)==dias_conv(k,1))&(fecha2011_anom
alias_pasopalas(l,2)==dias_conv(k,2))
                c=c+1;
            end
        end
        indicador_pasopalas(k)=c;
    end
    if(k>365)&(k<=731)
        c=0; %contador de anomalias
        for l=1:n2

            if(fecha2012_anomalias_pasopalas(l,1)==dias_conv(k,1))&(fecha2012_anom
alias_pasopalas(l,2)==dias_conv(k,2))
                c=c+1;
            end
        end
        indicador_pasopalas(k)=c;
    end
    if(k>731)&(k<=1096)
        c=0; %contador de anomalias
        for l=1:n3

```

```

if( fecha2013_anomalias_pasopalas(1,1)==dias_conv(k,1))&(fecha2013_anom
alias_pasopalas(1,2)==dias_conv(k,2))
    c=c+1;
    end
end
indicador_pasopalas(k)=c;
end
if(k>1096)
    c=0; %contador de anomalias
    for l=1:n4

if( fecha2014_anomalias_pasopalas(1,1)==dias_conv(k,1))&(fecha2014_anom
alias_pasopalas(1,2)==dias_conv(k,2))
    c=c+1;
    end
    end
    indicador_pasopalas(k)=c;
end
end

indicador2011_mensual=zeros(1,12);
indicador2012_mensual=zeros(1,12);
indicador2013_mensual=zeros(1,12);
indicador2014_mensual=zeros(1,9);
i=1;
for k=1:365
    if(dias_conv(k,2)==i)

indicador2011_mensual(i)=indicador2011_mensual(i)+indicador_pasopalas(
k);
        end
        if(dias_conv(k,2)>i)
            i=i+1;

indicador2011_mensual(i)=indicador2011_mensual(i)+indicador_pasopalas(
k);
        end
    end
    i=1;
    for k=366:731
        if(dias_conv(k,2)==i)

indicador2012_mensual(i)=indicador2012_mensual(i)+indicador_pasopalas(
k);
            end
            if(dias_conv(k,2)>i)
                i=i+1;

indicador2012_mensual(i)=indicador2012_mensual(i)+indicador_pasopalas(
k);
            end
        end
        i=1;
        for k=732:1096
            if(dias_conv(k,2)==i)

indicador2013_mensual(i)=indicador2013_mensual(i)+indicador_pasopalas(
k);
                end
                if(dias_conv(k,2)>i)

```

```

        i=i+1;

indicador2013_mensual(i)=indicador2013_mensual(i)+indicador_pasopalas(
k);
    end
end
i=1;
for k=1097:1277
    if(dias_conv(k,2)==i)

indicador2014_mensual(i)=indicador2014_mensual(i)+indicador_pasopalas(
k);
        end
        if(dias_conv(k,2)>i)
            i=i+1;

indicador2014_mensual(i)=indicador2014_mensual(i)+indicador_pasopalas(
k);
        end
    end

indicador_anual(1)=mean(indicador2011_mensual);
indicador_anual(2)=mean(indicador2012_mensual);
indicador_anual(3)=mean(indicador2013_mensual);
indicador_anual(4)=mean(indicador2014_mensual);

plot([365 365], [0, max(indicador_pasopalas)], 'k', [731 731], [0,
max(indicador_pasopalas)], 'k', [1096 1096], [0,
max(indicador_pasopalas)], 'k')

hold on
plot(1:n_fechas, indicador_pasopalas);
ylabel('Anomalies'); xlabel('Time');

```