

19



OFICINA ESPAÑOLA DE  
PATENTES Y MARCAS

ESPAÑA



11 Número de publicación: **2 987 306**

51 Int. Cl.:

**G01R 31/08** (2010.01)

**G01R 31/14** (2006.01)

**G01R 31/34** (2010.01)

**G01R 31/42** (2006.01)

**G01R 31/62** (2010.01)

12

TRADUCCIÓN DE PATENTE EUROPEA

T3

86 Fecha de presentación y número de la solicitud internacional: **27.12.2019 PCT/US2019/068840**

87 Fecha y número de publicación internacional: **02.07.2020 WO20140102**

96 Fecha de presentación y número de la solicitud europea: **27.12.2019 E 19904614 (5)**

97 Fecha y número de publicación de la concesión europea: **14.08.2024 EP 3903112**

54 Título: **Sistema y método para evaluar modelos de fallo predictivo de activos de energía renovable**

30 Prioridad:

**27.12.2018 US 201816234329**

45 Fecha de publicación y mención en BOPI de la traducción de la patente:

**14.11.2024**

73 Titular/es:

**UTOPUS INSIGHTS, INC. (100.0%)  
117 East Stevens Avenue Suite 200  
Valhalla, NY 10595, US**

72 Inventor/es:

**WANG, YAJUAN;  
GABOR, SOLYMOSSI y  
KIM, YOUNGHUN**

74 Agente/Representante:

**VALLEJO LÓPEZ, Juan Pedro**

ES 2 987 306 T3

Aviso: En el plazo de nueve meses a contar desde la fecha de publicación en el Boletín Europeo de Patentes, de la mención de concesión de la patente europea, cualquier persona podrá oponerse ante la Oficina Europea de Patentes a la patente concedida. La oposición deberá formularse por escrito y estar motivada; sólo se considerará como formulada una vez que se haya realizado el pago de la tasa de oposición (art. 99.1 del Convenio sobre Concesión de Patentes Europeas).

## DESCRIPCIÓN

Sistema y método para evaluar modelos de fallo predictivo de activos de energía renovable

5 **Campo de la invención**

Las realizaciones de la(s) presente(s) invención(es) se refieren en general a la previsión de fallos de activos de energía renovable y, en particular, a modelos de evaluación para predecir fallos de uno o más activos de energía renovable para aumentar el tiempo de espera antes del fallo y mejorar la precisión.

10

**Descripción de la técnica relacionada**

La detección y predicción de fallos en uno o más componentes de un activo de una red eléctrica ha sido difícil. La detección de un fallo de un componente de un activo es tediosa y alta en errores. En este ejemplo, un activo es un dispositivo para generar o distribuir energía en una red eléctrica. Los ejemplos de activos pueden incluir, aunque no de forma limitativa, una turbina eólica, generador de energía del panel solar, convertidor, transformador, distribuidor y/o similares. Dado que la detección de un fallo de un componente de un activo puede ser difícil de determinar, una mayor precisión de la predicción de fallos futuros complica los problemas.

15

20

La solicitud de patente de Estados Unidos US 2017/074250 A1 describe un método y sistema de monitorización de condiciones de turbinas eólicas. El método comprende: adquirir datos históricos de SCADA e informes de turbina eólica correspondientes a los datos históricos de SCADA; entrenar un modelo general para el diagnóstico general de la turbina eólica, y entrenar diferentes modelos individuales para analizar diferentes componentes de la turbina eólica basándose en los datos históricos de SCADA y el informe correspondiente de la turbina eólica, estableciendo una relación entre los datos SCADA históricos y el informe de turbina eólica; adquirir datos SCADA en tiempo real, introducir los datos SCADA en tiempo real en el modelo global entrenado, obtener la condición de salud de la turbina eólica a partir del modelo global entrenado, y realizar la etapa de diagnóstico individual si el modelo global entrenado determina que la turbina eólica tiene un estado defectuoso; introducir los datos SCADA en tiempo real en el modelo individual entrenado correspondiente al componente defectuoso, y obtener los detalles del fallo del componente defectuoso a partir del modelo individual entrenado correspondiente al componente defectuoso.

25

30

La solicitud de patente de Estados Unidos US 2012/191633 A1 describe un sistema de predicción de yacimientos implementado por ordenador, el método y software se proporcionan para la predicción de fallos para sistemas artificiales de extracción, tales como sistemas de bomba de varilla succionadora. El método incluye un pozo de producción asociado con un sistema artificial de extracción y datos indicativos de un estado operativo del sistema artificial de extracción. Se extraen una o más características de los datos del sistema artificial de extracción. La extracción de datos se aplica a la una o más características para determinar si se prevé que el sistema artificial de extracción falle dentro de un período de tiempo dado. Se emite una alerta indicativa de fallos inminentes del sistema artificial de extracción.

35

40

**Sumario**

Un ejemplo de medio legible por ordenador no transitorio que comprende instrucciones ejecutables, de acuerdo con la reivindicación 1, pudiendo las instrucciones ejecutables ejecutarse por uno o más procesadores para realizar un método, comprendiendo el método recibir primeros datos de sensor históricos de un primer período de tiempo, incluyendo los primeros datos de sensor históricos datos de sensor de uno o más sensores de uno o más componentes de cualquier número de activos de energía renovable, indicando los primeros datos de sensor históricos al menos un primer fallo asociado con el uno o más componentes del activo de energía renovable durante el primer período de tiempo, generar un primer conjunto de modelos de predicción de fallos usando los primeros datos de sensor históricos, entrenándose cada uno del primer conjunto de modelos de predicción de fallos por diferentes cantidades de primeros datos de sensor históricos basándose en diferentes ventanas de tiempo de observación y diferentes ventanas de tiempo de espera, incluyendo cada ventana de tiempo de observación un período de tiempo durante el cual se generan los primeros datos históricos, incluyendo la ventana de tiempo de espera un período de tiempo antes de un fallo previsto, evaluar cada modelo de predicción de fallos del primer conjunto de modelos de predicción de fallos usando al menos una matriz de confusión que incluye métricas para verdaderos positivos, falsos positivos, verdaderos negativos y falsos negativos, así como un valor de predicción positivo, seleccionar al menos un modelo de predicción de fallos del primer conjunto de modelos de predicción de fallos basándose en la evaluación de las matrices de confusión, los valores de predicción positivos y las ventanas de tiempo de espera para crear un primer modelo de predicción de fallos seleccionado, incluyendo el primer modelo de predicción de fallos seleccionado la ventana de tiempo de espera antes de un fallo previsto, recibir primeros datos de sensor actuales de un segundo período de tiempo, incluyendo los primeros datos de sensor actuales datos de sensor del uno o más sensores del uno o más componentes del activo de energía renovable, aplicar el primer modelo de predicción de fallos seleccionado a los datos de sensor actuales para generar una primera predicción de fallos de un fallo de al menos un componente del uno o más componentes, comparar la primera predicción de fallos con un primer criterio de activación, y generar y transmitir una primera alerta basándose en la comparación de la predicción de fallos con los primeros criterios de activación, indicando la alerta el al menos un componente del uno o más componentes e información con respecto a

55

60

65

la predicción de fallos.

En algunas realizaciones, el activo de energía renovable es una turbina eólica o un panel solar. Cada uno del primer conjunto de modelos de predicción de fallos puede predecir el fallo de un componente del activo renovable. El método puede comprender además seleccionar el primer umbral de activación de una pluralidad de umbrales de activación basándose en el componente, en donde cada umbral de activación diferente de la pluralidad de umbrales de activación se dirige a un componente o grupo de componentes diferente. En diferentes realizaciones, el método comprende además filtrar los primeros datos de sensor históricos para recuperar una porción de los datos de sensor históricos relacionados con el componente, comprendiendo generar el primer conjunto de modelos de predicción de fallos usando los primeros datos de sensor históricos generar el primer conjunto de modelos de predicción de fallos usando la porción de los primeros datos de sensor históricos.

En algunas realizaciones, el método puede comprender además generar un segundo conjunto de modelos de predicción de fallos usando los primeros datos de sensor históricos, entrenándose cada uno del segundo conjunto de modelos de predicción de fallos por diferentes cantidades de primeros datos de sensor históricos basándose en diferentes ventanas de tiempo de observación y diferentes ventanas de tiempo de espera, incluyendo cada ventana de tiempo de observación un período de tiempo durante el cual se generan los primeros datos históricos, incluyendo la ventana de tiempo de espera un período de tiempo antes de un fallo previsto, siendo el segundo conjunto de modelos de predicción de fallos para predecir un fallo de un componente que es diferente del primer conjunto de modelos de predicción de fallos, evaluar cada modelo de predicción de fallos del segundo conjunto de modelos de predicción de fallos usando al menos la matriz de confusión que incluye métricas para verdaderos positivos, falsos positivos, verdaderos negativos y falsos negativos, así como un valor de predicción positivo, comparar la matriz de confusión y el valor de predicción positivo de cada uno del segundo conjunto de modelos de predicción de fallos, seleccionar al menos un modelo de predicción de fallos del segundo conjunto de modelos de predicción de fallos basándose en la comparación de las matrices de confusión, los valores de predicción positivos y las ventanas de tiempo de espera para crear un segundo modelo de predicción de fallos seleccionado, incluyendo el segundo modelo de predicción de fallos seleccionado la ventana de tiempo de espera antes de un fallo previsto, recibir primeros datos de sensor actuales de un segundo período de tiempo, incluyendo los primeros datos de sensor actuales datos de sensor del uno o más sensores del uno o más componentes del activo de energía renovable, aplicar el segundo modelo de predicción de fallos seleccionado a los datos de sensor actuales para generar una segunda predicción de fallos, comparar la segunda predicción de fallos con un segundo criterio de activación, y generar y transmitir una segunda alerta basándose en la comparación de la predicción de fallos con los segundos criterios de activación, indicando la alerta el al menos un componente del uno o más componentes e información con respecto a la predicción de fallos.

El método puede comprender además filtrar los segundos datos de sensor históricos para recuperar una porción de los datos de sensor históricos relacionados con el componente, comprendiendo generar el segundo conjunto de modelos de predicción de fallos usando los primeros datos de sensor históricos generar el primer - segundo modelos de predicción de fallos usando la porción de los primeros datos de sensor históricos.

Seleccionar al menos un modelo de predicción de fallos del primer conjunto de modelos de predicción de fallos puede comprender generar un análisis de curvatura que incluye un indicador para cada modelo de predicción de fallos del primer conjunto de modelos de predicción de fallos en un gráfico usando diferentes ventanas de tiempo de espera y ventanas de tiempo de observación, proporcionando el análisis de curvatura un valor de predicción positivo para cada modelo de predicción de fallos del primer conjunto de modelos de predicción de fallos. Además, seleccionar al menos un modelo de predicción de fallos del primer conjunto de modelos de predicción de fallos puede comprender adicionalmente recibir una selección del modelo de predicción de fallos seleccionado usando el análisis de curvatura desde un dispositivo digital autorizado.

Un sistema de ejemplo puede comprender al menos un procesador y una memoria que contiene instrucciones, siendo las instrucciones ejecutables por el al menos un procesador para: recibir primeros datos de sensor históricos de un primer período de tiempo, incluyendo los primeros datos de sensor históricos datos de sensor de uno o más sensores de uno o más componentes de cualquier número de activos de energía renovable, indicando los primeros datos de sensor históricos al menos un primer fallo asociado con el uno o más componentes del activo de energía renovable durante el primer período de tiempo, generar un primer conjunto de modelos de predicción de fallos usando los primeros datos de sensor históricos, entrenándose cada uno del primer conjunto de modelos de predicción de fallos por diferentes cantidades de primeros datos de sensor históricos basándose en diferentes ventanas de tiempo de observación y diferentes ventanas de tiempo de espera, incluyendo cada ventana de tiempo de observación un período de tiempo durante el cual se generan los primeros datos históricos, incluyendo la ventana de tiempo de espera un período de tiempo antes de un fallo previsto, evaluar cada modelo de predicción de fallos del primer conjunto de modelos de predicción de fallos usando al menos una matriz de confusión que incluye métricas para verdaderos positivos, falsos positivos, verdaderos negativos y falsos negativos, así como un valor de predicción positivo, comparar la matriz de confusión y el valor de predicción positivo de cada uno del primer conjunto de modelos de predicción de fallos, seleccionar al menos un modelo de predicción de fallos del primer conjunto de modelos de predicción de fallos basándose en la comparación de las matrices de confusión, los valores de predicción positivos y las ventanas de tiempo de espera para crear un primer modelo de predicción de fallos seleccionado, incluyendo el primer modelo de predicción de fallos seleccionado la ventana de tiempo de espera antes de un fallo previsto, recibir primeros datos de

5 sensor actuales de un segundo período de tiempo, incluyendo los primeros datos de sensor actuales datos de sensor del uno o más sensores del uno o más componentes del activo de energía renovable, aplicar el primer modelo de predicción de fallos seleccionado a los datos de sensor actuales para generar una primera predicción de fallos de un fallo de al menos un componente del uno o más componentes, comparar la primera predicción de fallos con un primer criterio de activación, y generar y transmitir una primera alerta basándose en la comparación de la predicción de fallos con el primer criterio de activación, indicando la alerta el al menos un componente del uno o más componentes e información con respecto a la predicción de fallos.

10 Un método de ejemplo puede comprender recibir primeros datos de sensor históricos de un primer período de tiempo, incluyendo los primeros datos de sensor históricos datos de sensor de uno o más sensores de uno o más componentes de cualquier número de activos de energía renovable, indicando los primeros datos de sensor históricos al menos un primer fallo asociado con el uno o más componentes del activo de energía renovable durante el primer período de tiempo, generar un primer conjunto de modelos de predicción de fallos usando los primeros datos de sensor históricos, entrenándose cada uno del primer conjunto de modelos de predicción de fallos por diferentes cantidades de primeros datos de sensor históricos basándose en diferentes ventanas de tiempo de observación y diferentes ventanas de tiempo de espera, incluyendo cada ventana de tiempo de observación un período de tiempo durante el cual se generan los primeros datos históricos, incluyendo la ventana de tiempo de espera un período de tiempo antes de un fallo previsto, evaluar cada modelo de predicción de fallos del primer conjunto de modelos de predicción de fallos usando al menos una matriz de confusión que incluye métricas para verdaderos positivos, falsos positivos, verdaderos negativos y falsos negativos, así como un valor de predicción positivo, comparar la matriz de confusión y el valor de predicción positivo de cada uno del primer conjunto de modelos de predicción de fallos, seleccionar al menos un modelo de predicción de fallos del primer conjunto de modelos de predicción de fallos basándose en la comparación de las matrices de confusión, los valores de predicción positivos y las ventanas de tiempo de espera para crear un primer modelo de predicción de fallos seleccionado, incluyendo el primer modelo de predicción de fallos seleccionado la ventana de tiempo de espera antes de un fallo previsto, recibir primeros datos de sensor actuales de un segundo período de tiempo, incluyendo los primeros datos de sensor actuales datos de sensor del uno o más sensores del uno o más componentes del activo de energía renovable, aplicar el primer modelo de predicción de fallos seleccionado a los datos de sensor actuales para generar una primera predicción de fallos de un fallo de al menos un componente del uno o más componentes, comparar la primera predicción de fallos con un primer criterio de activación, y generar y transmitir una primera alerta basándose en la comparación de la predicción de fallos con los primeros criterios de activación, indicando la alerta el al menos un componente del uno o más componentes e información con respecto a la predicción de fallos.

### 35 Breve descripción de los dibujos

La Figura 1 representa un diagrama de bloques de un ejemplo de una red eléctrica en algunas realizaciones.

La Figura 2 representa componentes que a menudo producen fallos de turbinas eólicas y componentes que a menudo producen fallos en generadores de paneles solares.

La Figura 3 representa un problema común de detección de posibles fallos de uno o más componentes de un parque eólico.

La Figura 4 representa enfoques de predicción de fallos tradicionales de un fallo del cojinete del eje principal en turbinas eólicas, así como desafíos.

La Figura 5 es un diagrama de bloques de un sistema de predicción de fallos de componentes en algunas realizaciones.

La Figura 6 es un ejemplo de marco de evaluación longitudinal de predicción de fallos.

La Figura 7 representa un gráfico que define un triángulo de predicción factible de ejemplo como se define por el tiempo en retrospectiva y el tiempo de espera

La Figura 8 representa un análisis de curvatura que se puede hacer para cualquiera o todas las métricas de rendimiento.

La Figura 9 es un diagrama de flujo para predecir fallos y/o fallos potenciales de activos de energía renovable.

La Figura 10 representa un cálculo de un coste de mantenimiento predictivo de ejemplo en un ejemplo.

La Figura 11 es un gráfico de una optimización adicional del análisis de rendimiento por coste en algunas realizaciones.

La Figura 12 representa un diagrama de bloques de un servidor de sistema informático de ejemplo de acuerdo con algunas realizaciones.

## Descripción detallada

5 En la industria de generación eólica y solar, es crucial pronosticar con precisión los fallos de componentes con el mayor tiempo de espera posible. Algunas realizaciones descritas en el presente documento utilizan algoritmos de aprendizaje automático para construir un modelo de pronóstico sofisticado basándose en datos de sensor de múltiples variables para pronosticar fallos de componentes. Normalmente, existe una compensación entre la precisión del pronóstico de fallo de componente y la duración del tiempo pronosticado (por ejemplo, el tiempo previsto) antes de que se produzca el fallo. Como resultado, existe la necesidad de generar múltiples modelos para la evaluación y estandarizar la evaluación con el fin de obtener modelos que predigan con precisión el fallo en un período de tiempo aceptable antes del fallo previsto. Diversas realizaciones descritas en el presente documento superan las limitaciones de la técnica anterior, incluida la escalabilidad, advertencias proactivas y eficiencia computacional al tiempo que proporciona una precisión mejorada.

15 Históricamente, después de que se crean los modelos, se evalúan usando datos históricos para comparar la salida con la verdad conocida. Sin un conjunto estándar de métricas que incluya juicios cualitativos tales como falsos positivos y verdaderos negativos, diferentes métricas para diferentes componentes de un sistema entrenan modelos deficientes. Tales modelos harán que la predicción de fallos sea inconsistente, particularmente a través de diferentes sistemas. La precisión mal definida de un modelo puede conducir a "ingeniería de métricas de rendimiento" (por ejemplo, indicando que un modelo es un pronóstico preciso por término de "hasta 30 días de predicción" cuando el modelo solo predice un fallo 1 día antes del fallo).

25 Sin un conjunto estándar de métricas que incluya juicios cualitativos, es cada vez más difícil generar diferentes modelos y evaluar los modelos para diferentes ventanas de tiempo de espera antes del fallo previsto con un grado satisfactorio de precisión de la predicción. Se apreciará que cuanto más tiempo se pronostiquen los fallos en el futuro, más útiles pueden ser esas predicciones. Sin embargo, el tiempo de predicción más largo impacta en la precisión de la predicción. De esta manera, los modelos de predicción deben evaluarse para proporcionar un tiempo de espera aceptable con un nivel aceptable de precisión. Para lograr esto de manera consistente a través de muchos componentes diferentes de muchos activos de energía renovable diferentes, debe usarse un conjunto estándar de métricas.

35 En algunas realizaciones, la evaluación del rendimiento del modelo puede usarse para medir el éxito de diferentes modelos de predicción y, como resultado, proporcionar un marco para que los usuarios tomen una decisión informada sobre la predicción de fallos.

Se apreciará que mejorar la precisión y estandarización de los modelos de predicción de fallos para componentes de activos de energía renovable mejora la creación de modelos, la evaluación del rendimiento del modelo del pasado, y mejora la escalabilidad (todas las cuales son inherentes en el campo de la tecnología informática).

40 La Figura 1 representa un diagrama de bloques 100 de un ejemplo de una red eléctrica 100 en algunas realizaciones. La Figura 1 incluye una red eléctrica 102, un sistema de predicción de fallos de componentes 104, un sistema de alimentación 106, en comunicación a través de una red de comunicación 108. La red eléctrica 102 incluye cualquier número de líneas de transmisión 110, fuentes de energía renovable 112, subestaciones 114 y transformadores 116. La red eléctrica 102 puede incluir cualquier número de activos eléctricos, incluidos los activos de protección (por ejemplo, relés u otros circuitos para proteger uno o más activos), activos de transmisión (por ejemplo, líneas o dispositivos para suministrar o recibir energía) y/o cargas (por ejemplo, casas residenciales, negocios comerciales y/o similares).

50 Los componentes de la red eléctrica 102, tales como la(s) línea(s) de transmisión 110, la(s) fuente(s) de energía renovable 112, la(s) subestación(es) 114 y/o el(los) transformador(es) 106 pueden inyectar energía o potencia (o ayudar en la inyección de energía o potencia) en la red eléctrica 102. Cada componente de la red eléctrica 102 puede representarse por cualquier número de nodos en una representación de red de la red eléctrica. Las fuentes de energía renovable 112 pueden incluir paneles solares, turbinas eólicas y/u otras formas de la denominada "energía verde". La red eléctrica 102 puede incluir una red de red eléctrica amplia (por ejemplo, con 40.000 activos o más).

55 Cada activo eléctrico de la red eléctrica 100 puede representar uno o más elementos de sus respectivos activos. Por ejemplo, el(los) transformador(es) 116, como se muestra en la Figura 1 puede representar cualquier número de transformadores que componen la red eléctrica 100.

60 En algunas realizaciones, el sistema de predicción de fallos de componentes 104 puede configurarse para recibir datos de sensor históricos desde cualquier número de sensores de cualquier número de activos eléctricos. El sistema de predicción de fallos de componentes 104 puede generar posteriormente cualquier número de modelos para predecir fallos de cualquier número de componentes. Pueden generarse diferentes modelos para el(los) mismo(s) componente(s) basándose en un conjunto común de métricas.

65 Cada modelo puede evaluarse para determinar la precisión del modelo y la duración de tiempo antes del fallo previsto

en el nivel deseado de precisión. De esta manera, el sistema de predicción de fallos de componentes 104 puede usarse para generar y evaluar múltiples modelos usando los mismos datos de sensor históricos pero cada uno con diferentes períodos de tiempo antes del fallo previsto para identificar al menos un modelo con una precisión aceptable en un tiempo de predicción aceptable antes de que se espere que ocurra un fallo de componente.

5 En algunas realizaciones, la red de comunicación 108 representa una o más redes informáticas (por ejemplo, LAN, WAN y/o similares). La red de comunicación 108 puede proporcionar comunicación entre cualquiera del sistema de mitigación de congestión 104, el sistema de alimentación 106 y/o la red eléctrica 102. En algunas implementaciones, la red de comunicación 108 comprende dispositivos informáticos, enrutadores, cables, utilidades y/u otras topologías de red. En algunas realizaciones, a red de comunicación 108 puede ser cableada o inalámbrica. En diferentes realizaciones, la red de comunicación 108 puede comprender Internet, una o más redes que pueden ser públicas, privadas, basado en IP, no basadas en IP, y así sucesivamente.

15 El sistema de predicción de fallos de componentes 104 puede incluir cualquier número de dispositivos digitales configurados para pronosticar fallos de componentes de cualquier número de componentes y/o generadores (por ejemplo, turbina eólica o generador de energía solar) de las fuentes de energía renovable 112.

20 El sistema de alimentación 106 puede incluir cualquier número de dispositivos digitales configurados para controlar la distribución y/o transmisión de energía. El sistema de alimentación 106 puede, en un ejemplo, controlarse por una compañía eléctrica, servicios públicos y/o similares. Un dispositivo digital es cualquier dispositivo con al menos un procesador y memoria. Ejemplos de sistemas, entornos y/o configuraciones que pueden ser adecuados para su uso con el sistema incluyen, pero no se limitan a, sistemas informáticos personales, sistemas informáticos de servidor, clientes pequeños, clientes de gran tamaño, dispositivos de mano o portátiles, sistemas multiprocesador, sistemas basados en microprocesador, decodificadores, electrónicas de consumo programable, PC de red, sistemas de miniordenador, sistemas informáticos centrales y entornos informáticos en la nube distribuidos que incluyen cualquiera de los sistemas o dispositivos anteriores, y similares.

30 Un sistema informático puede describirse en el contexto general de instrucciones ejecutables de sistema informático, tales como módulos de programa, que son ejecutados por un sistema informático. Generalmente, los módulos de programa pueden incluir rutinas, programas, objetos, componentes, lógica, estructuras de datos, etc., que realizan tareas particulares o implementan tipos de datos abstractos particulares. Un dispositivo digital, tal como un sistema informático, se describe además con respecto a la Figura 22.

35 La Figura 2 representa componentes que a menudo producen fallos de turbinas eólicas y componentes que a menudo producen fallos en generadores de paneles solares. Los fallos en las turbinas eólicas a menudo se producen como resultado de fallos en un cojinete principal 202, caja de engranajes 204, generador 206 o anemómetro 208. Los fallos en los generadores de paneles solares a menudo se producen como resultado de fallos en un inversor 210, degradación de panel 212 y un IGBT 214.

40 Una turbina eólica tiene muchos componentes potenciales de fallo. Diferentes sensores pueden proporcionar diferentes lecturas para uno o más componentes o combinaciones de componentes diferentes. Dado el número de turbinas eólicas en un parque eólico, la cantidad de datos a evaluar puede ser insostenible usando los métodos de la técnica anterior. Por ejemplo, los sistemas de análisis de datos de la técnica anterior no escalan, los sensores proporcionan demasiados datos para ser evaluados por los sistemas de la técnica anterior, y existe una falta de capacidad de cálculo en los sistemas de la técnica anterior para evaluar eficazmente los datos de los parques eólicos de manera sensible al tiempo. Como resultado, los sistemas de la técnica anterior son reactivos a los fallos existentes en lugar de proporcionar proactivamente informes o advertencias de posibles fallos futuros de uno o más componentes.

50 Por ejemplo, diversas realizaciones con respecto a una turbina eólica descrita en el presente documento pueden identificar un fallo potencial de un cojinete principal 202, caja de engranajes 204, generador 206 o anemómetro 208 de una o más turbinas eólicas. Aunque se pueden utilizar muchos cojinetes en una turbina eólica (por ejemplo, cojinetes de guiñada y cabeceo), el eje principal y la caja de engranajes de la turbina eólica tienden a ser los más problemáticos. Por ejemplo, un cojinete principal 202 puede fallar debido a una alta carga de empuje o puede fallar debido a una generación inadecuada de película lubricante. Las tendencias en el rediseño de un eje principal 202 y/o caja de engranajes 204 de una única turbina eólica han sido impulsadas por fallos inesperados en estas unidades. El reemplazo no planificado del cojinete de árbol principal 202 puede costar a los operadores hasta 450.000 dólares y tener un impacto obvio en el rendimiento financiero.

60 Los fallos de la caja de engranajes 204 son una de las mayores fuentes de costes de mantenimiento no planificados. Los fallos de la caja de engranajes 204 pueden ser causados por problemas de diseño, defectos de fabricación, deficiencias en el lubricante, tiempo excesivo en parada, alta carga y otras razones. Puede haber muchos modos diferentes de fallo de la caja de engranajes 204 y, de esta manera, puede ser importante identificar el tipo de modo de fallo al abordar el fallo. Un modo es la microcorrosión por picadura que se produce cuando la película lubricante entre las superficies en contacto en una caja de engranajes 204 no es lo suficientemente gruesa. La macrocorrosión por picadura se produce cuando la tensión de contacto en un engranaje o la rotura supera la resistencia a la fatiga del

material. La fatiga por flexión, un modo de fallo que afecta a los dientes de engranaje y al agrietamiento axial, puede producirse en los cojinetes de una caja de engranajes; las grietas se desarrollan en la dirección axial, perpendicular a la dirección de laminación.

- 5 El generador 206 normalmente convierte la energía eólica en energía eléctrica. Los fallos a menudo ocurren en los cojinetes, el estátor, el rotor o similares que pueden conducir a una tensión inconsistente con un fallo total. El fallo del generador 206 puede ser difícil de detectar como resultado de un clima inconsistente, falta de movimiento y/o fallo parcial del anemómetro 208.
- 10 El anemómetro 208 usa partes móviles como sensores. Los anemómetros 208 a menudo incluyen "copas" para mediciones de velocidad del viento y una veleta que usa una "cola de veleta" para medir el cambio de vector o la dirección del viento. El clima helado ha provocado que las "copas" y la "cola de veleta" se bloqueen. Si un anemómetro 208 informa menos de la velocidad del viento debido a un fallo parcial, hay un aumento en la aceleración del rotor que indica que una gran cantidad de energía eólica no se convierte en ingeniería eléctrica. La resistencia a la rodadura en los cojinetes de un anemómetro 208 normalmente aumenta con el tiempo hasta que se agarrotan. Además, si el anemómetro 208 no es preciso, la turbina eólica no controlará el paso de pala ni la velocidad de rotor según sea necesario. Las mediciones deficientes o inexactas del anemómetro 208 conducirán a ajustes incorrectos y a una mayor fatiga.
- 20 De manera similar, diversas realizaciones con respecto a un generador de panel solar descrito en el presente documento pueden identificar un fallo potencial de un inversor 210, panel solar 212 e IGBT 214 en uno o más paneles solares de una granja solar.

25 Un inversor solar 210 es un convertidor eléctrico para convertir la corriente continua variable de un panel solar fotovoltaico 212 en una corriente alterna de frecuencia de servicio que puede alimentarse a una red eléctrica. Las pérdidas de producción a menudo son atribuibles a un rendimiento deficiente de los inversores 210. Los inventores solares 210 pueden sobrecalentarse (causado por el clima, uso o fallo de los sistemas de enfriamiento) lo que puede reducir la producción. La humedad puede provocar un cortocircuito que puede provocar un fallo total o parcial (por ejemplo, a un nivel de aislamiento mínimo "requerido"). Además, el hecho de que el inversor solar 210 no se reinicie después de un fallo enmarcado puede requerir el reinicio manual del equipo.

30 El panel 212 se refiere al panel solar o fotovoltaico. El panel fotovoltaico 212 puede degradarse debido al clima, mala limpieza, ciclado térmico, calor húmedo, congelación por humedad y exposición a los rayos UV. Los ciclos térmicos pueden causar fallos y grietas en la unión de la soldadura. El calor húmedo se ha asociado con la delaminación de los encapsulantes y la corrosión de las células. La congelación por humedad puede hacer que falle la adhesión de la caja de conexiones. La exposición a los rayos UV contribuye a la decoloración y degradación de la lámina posterior.

35 Los inversores solares 210 a menudo usan transistores bipolares de puerta aislada (IGBT) 214 para la conversión de la salida del panel solar 212 a tensión de CA. Los fallos en los IGBT 214 pueden ser causados por fatiga, corrosión de metalizaciones, electromigración de metalizaciones, formación de filamentos conductores, formación de huecos por difusión impulsada por la tensión y ruptura dieléctrica dependiente del tiempo.

40 La Figura 3 representa un problema común de detección de posibles fallos de uno o más componentes de un parque eólico. Como se muestra en la Figura 3, puede haber cualquier número de turbinas eólicas en un parque eólico. Los sensores de cada turbina eólica en un parque eólico pueden generar sus propios datos. Como resultado, hay un volcado de datos de series temporales que es abrumador para los sistemas de la técnica anterior y los métodos de evaluación de la técnica anterior. Como se ilustra, monitorizar cientos de activos con cientos de entradas de sensor requiere mucho tiempo y es abrumador para que los operadores lo prueben. Como consecuencia adicional, evaluar diferentes modelos para diferentes componentes para predecir fallos en esos componentes se vuelve difícil y la precisión puede verse afectada a medida que aumenta el tiempo deseado para predecir fallos de componentes.

45 Los sistemas existentes de la técnica anterior reciben demasiados datos de series de tiempo para evaluarse eficazmente de una manera escalable y/o computacionalmente eficiente. Como resultado, hay una respuesta conservadora y/o reactiva al fallo de los componentes y de la turbina eólica. En otras palabras, la acción generalmente se toma mucho después de que se detecta el fallo o cuando el fallo es inmanente e inconfundible.

50 La Figura 4 representa enfoques de predicción de fallos tradicionales de un fallo del cojinete del eje principal en turbinas eólicas, así como desafíos. En este ejemplo, el fallo del cojinete del eje principal puede ser causado por cualquier número de componentes. Para el análisis de la técnica anterior, los desafíos incluyen identificar el modelo de sistemas mecánicos correcto y los modos de operación nominales de ese modelo de sistema mecánico.

55 Los enfoques de la técnica anterior también pueden fallar debido a una asignación incorrecta de datos de sensor. La asignación de datos de sensor puede basarse en la capacidad de observación y tener en cuenta el alcance dinámico del sensor. En este ejemplo del fallo del cojinete del eje principal, los datos de sensor con respecto a la temperatura, ruido y/o vibración pueden tenerse en cuenta. Por ejemplo, los datos de sensor relacionados con la temperatura, ruido y/o vibración se observan en el contexto de otras lecturas de datos de sensor, y debe reconocerse el alcance dinámico

de sensor de cada sensor individual o combinación de sensores.

Los sistemas de la técnica anterior a menudo fallan al ajustar un umbral de detección de fallos para una lectura de sensor. Los sistemas de la técnica anterior normalmente deben identificar parámetros específicos de modelo y parámetros específicos de sitio. En este caso, los datos de sensor de temperatura pueden indicar una advertencia de temperatura alta en relación con algún umbral de temperatura alta. Los datos de ruido pueden utilizarse para análisis de frecuencia resonante para detectar resonancias dentro de un componente o dispositivo. Los datos de vibración pueden evaluarse para determinar una vibración excesiva en relación con algún umbral de vibración.

10 La indicación temprana adicional de fallos en la temperatura, ruido, vibración u otros fallos, puede pasarse por alto fácilmente si su modo de operación nominal está definido libremente por el sistema de la técnica anterior.

15 La Figura 5 es un diagrama de bloques de un sistema de predicción de fallos de componentes 104 en algunas realizaciones. El sistema de predicción de fallos de componentes 104 puede predecir un fallo de componente antes del fallo real. El sistema de predicción de fallos de componente 104 puede entrenar y evaluar cualquier número de modelos que predicen fallo de componente. En algunas realizaciones, el sistema de predicción de fallos de componentes 104 entrena un conjunto de modelos de predicción de fallos de componentes para cada componente o conjunto de componentes usando datos de sensor históricos recibidos de sensores de cualquier número de activos eléctricos (por ejemplo, incluyendo activos eléctricos de energía renovable tales como turbinas eólicas). En algunas realizaciones, cada conjunto de modelos predice el fallo de un componente diferente del mismo o de diferentes activos eléctricos.

25 El sistema de predicción de fallos de componentes 104 puede entrenar diferentes modelos de predicción de fallos de un conjunto usando las mismas métricas de datos de sensor históricos, pero con diferentes tiempos de espera y con diferentes cantidades de datos de sensor históricos (por ejemplo, diferentes cantidades de tiempos en retrospectiva). El sistema de predicción de fallos de componentes 104 puede evaluar los modelos de predicción de fallos del conjunto basados en la sensibilidad, precisión y/o especificidad para los diferentes tiempos retrospectivos y de espera. Como resultado, el sistema de predicción de fallos de componentes 104 puede seleccionar un modelo de predicción de fallos de un conjunto de modelos de predicción de fallos para cada tipo de componente (por ejemplo, cojinete), componente (por ejemplo, cojinete(s) específico(s) en uno o más activos), tipo de grupo de componentes (por ejemplo, generador que incluye dos o más componentes), grupo de componentes (por ejemplo, generador(es) específico(s) que incluyen dos o más componentes en uno o más activos), tipo de activo (por ejemplo, turbinas eólicas), o grupo de activos (por ejemplo, conjunto específico de turbinas eólicas).

35 Las métricas usadas para evaluar el rendimiento (por ejemplo, basándose en los valores de las lecturas de sensor y/o de los propios sensores) pueden ser las mismas para diferentes componentes incluso si los datos de sensor de los sensores de los diferentes componentes son diferentes. Al estandarizar las métricas para la evaluación, el sistema de predicción de fallos de componentes 104 puede "ajustar" o cambiar aspectos del modelo de predicción de fallos y el entrenamiento del modelo para lograr los objetivos de precisión aceptable con un tiempo de espera aceptable antes del fallo previsto. Esto permite una precisión mejorada para diferentes componentes de un activo eléctrico con un tiempo de predicción mejorado (por ejemplo, se prefieren tiempos de predicción más largos).

45 En algunas realizaciones, el sistema de predicción de fallos de componentes 104 puede aplicar un algoritmo de detección de anomalías de múltiples variables a los sensores que están monitorizando las condiciones operativas de cualquier número de activos renovables (por ejemplo, turbinas eólicas y/o generadores solares). El sistema de predicción de fallos de componentes 104 puede eliminar datos asociados con un fallo pasado, real del sistema (por ejemplo, de cualquier número de componentes y/o dispositivos), por lo tanto, destacando anomalías sutiles de las condiciones operativas normales que conducen a fallos reales.

50 El sistema de predicción de fallos de componentes 104 puede ajustar con precisión los modelos de predicción de fallos aplicando técnicas de reducción de dimensionalidad para eliminar el ruido de los datos de sensor irrelevantes (por ejemplo, aplicar análisis de componentes principales para generar un modelo de predicción de fallos usando datos y/o características linealmente no correlacionadas a partir de los datos). Por ejemplo, el sistema de predicción de fallos de componentes 104 puede utilizar análisis factorial para identificar la importancia de las características dentro de los datos de sensor. El sistema de predicción de fallos de componente 104 también puede utilizar uno o más vectores de ponderación para resaltar una porción o subconjunto de datos de sensor que tiene un alto impacto en el fallo.

60 En algunas realizaciones, el sistema de predicción de fallos de componentes 104 puede abarcar adicionalmente datos de series de tiempo de los datos de sensor eliminando algunos datos de sensor del periodo de tiempo de fallo real. En diferentes realizaciones, el sistema de predicción de fallos de componentes 104 puede utilizar opcionalmente características de datos seleccionadas para mejorar la precisión de detección. La detección de fallo de la caja de engranajes, por ejemplo, puede utilizar el aumento de temperatura en la caja de engranajes con respecto a la generación de energía, potencia reactiva y temperatura ambiente.

65 En algunas realizaciones, el sistema de predicción de fallos de componentes 104 puede recibir datos de sensor históricos con respecto a fuentes de energía renovable (por ejemplo, turbinas eólicas, paneles solares, parques

eólicos, granjas solares, concesiones eléctricas y/o similares). El sistema de predicción de fallos de componentes 104 puede desglosar los datos para identificar características importantes y eliminar el ruido de fallos pasados que pueden impactar en la construcción de modelos. Los datos históricos pueden seleccionarse para identificar adicionalmente características importantes y eliminar el ruido. El sistema de predicción de fallos de componentes 104 puede identificar adicionalmente etiquetas o categorías para aprendizaje automático. Se apreciará que el sistema de predicción de fallos de componentes 104 puede, en algunas realizaciones, identificar etiquetas.

El sistema de predicción de fallos de componentes 104 puede recibir datos de sensor con respecto a cualquier número de componentes desde cualquier número de dispositivos, tales como turbinas eólicas de un parque eólico. Los datos de sensor pueden incluir datos de series temporales multivariantes que, cuando se combinan con las etiquetas o categorías para el aprendizaje automático, pueden ayudar a la minería de variables latentes de aprendizaje profundo, pueden proporcionar información para la indicación de fallos de componentes. Estas percepciones, que pueden predecir próximos fallos, pueden habilitar de manera efectiva las respuestas a los próximos fallos con suficiente tiempo de espera antes de que el fallo impacte en otros componentes de la generación de energía.

Se apreciará que identificar fallos próximos para cualquier número de componentes y generación de energía renovable puede volverse cada vez más importante a medida que las fuentes de energía migran a energía renovable. El fallo de uno o más componentes puede afectar significativamente a la red y, como resultado, puede poner la red eléctrica o los componentes heredados de la red eléctrica, ya sea bajo carga o hacer que fallen por completo. Además, los fallos de la red eléctrica y/o los fallos de las fuentes de energía renovable pueden amenazar la pérdida de propiedad, negocios o la vida, particularmente en momentos en los que la energía es crítica (por ejemplo, sistemas hospitalarios, condiciones climáticas severas tales como olas de calor, ventiscas o huracanes, cuidado de enfermos, cuidado de ancianos y/o cuidado de jóvenes).

El sistema de predicción de fallos de componentes 104 puede comprender un módulo de comunicación 502, un módulo de preparación de datos de entrenamiento 504, un módulo de entrenamiento de modelos 506, un módulo de evaluación de modelo 508, un módulo de aplicación modelo 510, un módulo de activación 512, un módulo de generación de informes y alertas 514 y un almacenamiento de datos 516.

El módulo de comunicación 502 puede configurarse para transmitir y recibir datos entre dos o más módulos en el sistema de predicción de fallos de componentes 104. En algunas realizaciones, el módulo de comunicación 502 está configurado para recibir información con respecto a los activos de la red eléctrica 102 (por ejemplo, del sistema de alimentación 106, sensores dentro de los componentes de la red eléctrica 102, tales como las fuentes de energía renovable 112, sistemas de terceros tales como entidades gubernamentales, otros servicios públicos y/o similares).

El módulo de comunicación 502 puede configurarse para recibir datos de sensor históricos con respecto a activos eléctricos, ya sea individualmente o en combinación (por ejemplo, turbinas eólicas, paneles solares, parques eólicos, granjas solares, componentes de dispositivos, componentes de turbinas eólicas, componentes de paneles solares, subestaciones 114, transformadores 116 y/o líneas de transmisión 110). El módulo de comunicación 502 puede recibir adicionalmente datos de sensor desde uno o más sensores de cualquier número de activos eléctricos tales como los descritos anteriormente.

El módulo de preparación de datos de entrenamiento 504 puede preparar opcionalmente los datos de sensor históricos para módulos de predicción de fallos de entrenamiento. En diferentes realizaciones, el módulo de preparación de datos de entrenamiento 504 puede extraer características (por ejemplo, dimensiones y/o variables) a partir de los datos de sensor históricos recibidos. Los datos de sensor multivariantes pueden, como se comenta en el presente documento, ser datos de series de tiempo. Por ejemplo, el módulo de preparación de datos de entrenamiento 504 puede extraer características de los datos de series de tiempo. El módulo de preparación de datos de entrenamiento 504 puede proporcionar las características extraídas al módulo de entrenamiento de modelo 506 para entrenar uno o más modelos.

En diferentes realizaciones, la extracción de características también puede referirse al proceso de creación de nuevas características a partir de un conjunto inicial de datos. Estas características pueden encapsular propiedades centrales de un conjunto de datos y representar el conjunto de datos y un espacio de baja dimensión que facilita el aprendizaje. Como puede apreciarse, los datos de sensor multivariantes iniciales pueden incluir una serie de características que son demasiado grandes y difíciles de manejar para gestionarse de manera efectiva y pueden requerir una cantidad irrazonable de recursos informáticos. La extracción de características puede usarse para proporcionar un subconjunto representativo más manejable de variables de entrada. Se apreciará que la extracción de características puede extraer características para los datos, así como crear nuevas características a partir del conjunto inicial de datos.

Se apreciará que, en algunas realizaciones, las dimensiones pueden referirse a columnas (por ejemplo, características o variables) de los datos de sensor históricos recibidos.

El módulo de entrenamiento de modelo 506 puede utilizar algoritmos de clasificación para entrenamiento de modelo. Las clasificaciones pueden incluir, por ejemplo, SVM, DeepLearning (tal como CNN o CHAID). La entrada del modelo de entrenamiento puede incluir una entrada equilibrada tal como, por ejemplo, datos de sensor históricos,

características extraídas de los datos de sensor históricos, series temporales de anomalías de alcance a partir de los datos de sensor históricos, series temporales de sensor ponderadas con alcance a partir de los datos de sensor históricos y/o indicaciones de fallo. En algunas realizaciones, los datos de serie de tiempo son una matriz donde el tiempo de inicio y el tiempo de finalización de la serie de tiempo incluyen el tiempo de espera máximo, tiempo de espera mínimo y por horizonte de tiempo deseado (por ejemplo, 45 días a 10 días antes de un evento).

El módulo de entrenamiento de modelo 506 puede generar cualquier número de modelos de predicción de fallos usando los datos de sensor históricos y diferentes configuraciones para el tiempo de espera. Por ejemplo, el módulo de entrenamiento de modelos 506 puede generar diferentes modelos de predicción de fallos de un conjunto de módulos de predicción de fallos usando diferentes cantidades de datos de sensor históricos (por ejemplo, datos de sensor históricos generados durante diferentes períodos de tiempo) y con diferentes tiempos de anticipación de espera. El módulo de evaluación de modelos 508 puede evaluar cualquiera o todos los modelos de predicción de fallos de cada conjunto generados por el módulo de entrenamiento de modelos 506 para identificar un modelo de predicción de fallos preferido de un conjunto en comparación con los otros modelos de predicción de fallos preferidos de un conjunto basándose en criterios (por ejemplo, se prefieren tiempos de espera más largos).

La Figura 6 caracteriza problemas y propone soluciones en algunas realizaciones. El gráfico en la figura 6 representa lecturas de sensor de múltiples sensores durante un período de tiempo que conduce al fallo. El tiempo antes del fallo se indica como "tiempo de espera". Un objetivo puede ser mejorar el tiempo de espera con suficiente precisión de modo que puedan emitirse alertas y/o tomarse acciones para mitigar las consecuencias de fallo o evitar fallo antes de que ocurra ese fallo.

La Figura 6 es un ejemplo de marco de evaluación longitudinal de predicción de fallos. El marco de evaluación longitudinal incluye tres períodos de tiempo, incluyendo un período de tiempo de predicción, una ventana de tiempo de anticipación y un período de tiempo previsto. En algunas realizaciones, los datos de sensor recibidos y/o generados durante el período de tiempo de predicción pueden usarse para la construcción de modelos y el reconocimiento de patrones. Las etiquetas de evento de fallo pueden extraerse de la duración de la ventana de tiempo prevista.

El período de tiempo de predicción es una ventana de tiempo de observación en la que los datos de sensor históricos que fueron generados por los sensores durante esta ventana de tiempo y/o recibidos durante esta ventana de tiempo se usan para la creación de modelos de predicción de fallos y el reconocimiento de patrones para diferentes modelos (por ejemplo, con diferentes cantidades de tiempo en retrospectiva). La ventana de tiempo de anticipación es un período de tiempo en que los datos de sensor generados durante esta ventana de tiempo y/o recibidos durante esta ventana de tiempo no se usan para la construcción de modelo ni para el reconocimiento de patrón. En diferentes realizaciones, los datos de sensor generados y/o recibidos durante la ventana de tiempo de anticipación pueden usarse para probar cualquiera o todos los modelos de predicción de fallos. La ventana de tiempo prevista es un período de tiempo en el que se espera que ocurra un fallo.

En el ejemplo de la Figura 6, el período de tiempo de predicción es de -45 días a -1 día (antes de la ventana de tiempo de anticipación) y la ventana de tiempo prevista es de 0 a 2 días después de la ventana de tiempo de anticipación. Pueden generarse diferentes modelos de predicción de fallos con diferentes cantidades de períodos de tiempo de predicción (por ejemplo, diferentes modelos usan un número diferente de días de datos de sensor) y diferentes cantidades de tiempos de anticipación (por ejemplo, diferentes modelos usan un número diferente de días antes del fallo previsto).

Se apreciará que el periodo de tiempo previsto puede ser cualquier longitud de tiempo antes de la ventana de tiempo de anticipación y que la ventana de tiempo prevista puede ser cualquier longitud de tiempo después de la ventana de tiempo de anticipación. Uno de los objetivos en algunas realizaciones descritas en el presente documento es lograr un nivel aceptable de precisión de un modelo con un tiempo de espera suficiente antes de la ventana de tiempo prevista para permitir acciones proactivas para evitar fallos, para escalar el sistema para permitir la detección de un número de fallos de componentes, y para mejorar la precisión del sistema (por ejemplo, para evitar falsos positivos).

Además, como se usa en el presente documento, un periodo de entrenamiento de modelo puede incluir un periodo de tiempo usado para seleccionar instancias de entrenamiento. Una instancia es un conjunto de características de serie temporal/evento junto con el fallo/no fallo de un componente particular en un activo de energía renovable (por ejemplo, una turbina eólica) en un período de tiempo especificado. Un periodo de prueba de modelo es un periodo de tiempo usado para seleccionar instancias de prueba.

En algunas realizaciones, una entrada equilibrada puede requerir un mínimo de historial de fallos (por ejemplo, 20 %) que puede copiarse submuestreando el historial sin fallos y potenciando los datos históricos de fallos (por ejemplo, ventana deslizante para los datos históricos de fallos).

En diferentes realizaciones, el módulo de entrenamiento de modelo 506 y/o el módulo de preparación de datos de entrenamiento 504 pueden filtrar los datos de sensor históricos para extraer datos relacionados con un único componente, un tipo de componente o una combinación específica de componentes. El módulo de entrenamiento de modelos 506 puede generar modelos de predicción de fallos específicos (por ejemplo, un conjunto de modelos de

predicción de fallos) para cada componente, tipo de componente (por ejemplo, rotor, cojinete, generador y similares), combinación específica de componentes y/o activo eléctrico. Como resultado, el módulo de entrenamiento de modelos 506 puede, en algunas realizaciones, generar una pluralidad de modelos diferentes para una pluralidad de componentes diferentes.

5 La Figura 7 representa un gráfico que define un triángulo de predicción factible de ejemplo como se define por el tiempo en retrospectiva y el tiempo de espera. El módulo de entrenamiento de modelo 506 puede definir el triángulo de predicción factible basándose en la determinación de un tiempo en retrospectiva y un tiempo de espera. El triángulo de predicción factible puede utilizarse adicionalmente para optimización.

10 En diferentes realizaciones, el módulo de entrenamiento de modelo 506 puede identificar diferentes tiempos en retrospectiva (por ejemplo, diferentes periodos de tiempo de predicción) evaluando diferentes cantidades de datos de sensor históricos e identificando diferentes tiempos de espera. Por ejemplo, el sistema de predicción de fallos de componentes 104 puede recibir dos meses de datos de sensor históricos. El sistema de predicción de fallos de componentes 104 puede entrenar un modelo de predicción de fallos usando 45 días de datos de sensor históricos, otro modelo de predicción de fallos del mismo conjunto usando 40 días de los mismos datos de sensor históricos de sensor, un tercer modelo de predicción de fallos del mismo conjunto usando 35 días de los mismos datos de sensor históricos de sensor, y así sucesivamente. De manera similar, para cualquier número de modelos de predicción de fallos, el sistema de predicción de fallos de componentes 104 puede utilizar diferentes cantidades de tiempo de espera definiendo así el triángulo de predicción factible de manera diferente para cada evaluación de modelo de predicción de fallos con el fin de determinar el modelo más preferido basándose en el tiempo y la evaluación métrica del rendimiento.

25 El módulo de evaluación de modelo 508 está configurado para evaluar el rendimiento de los modelos de predicción de fallos generados por el módulo de entrenamiento de modelo 506. En algunas realizaciones, el módulo de evaluación de modelo 508 puede realizar una validación cruzada (CV) x veces en conjuntos de datos de entrenamiento para establecer el rendimiento de CV, incluyendo la incertidumbre de predicción. El módulo de evaluación de modelo 508 puede probar el modelo desarrollado en conjuntos de datos de prueba equilibrados (por ejemplo, aproximadamente 50:50 (sistemas fallidos y no fallidos) o para ajustarse para el resultado comercial deseado).

30 En diferentes realizaciones, el módulo de evaluación de modelo 508 compara las predicciones de cada modelo de predicción de fallos de un conjunto de modelos de predicción de fallos usando datos de sensor históricos para comparar los resultados con la verdad en el terreno (por ejemplo, fallos conocidos y períodos de tiempo conocidos en los que el componente no falló). El módulo de evaluación de modelo 508 puede separar los resultados en categorías cualitativas que incluyen verdaderos positivos (TP), falsos positivos (FP), verdaderos negativos (TN), falsos negativos (FN), positivos (TP+FN) y negativos (TN+FP).

40 El módulo de evaluación de modelo 508 puede utilizar unas medidas de rendimiento de predicción de fallos (por ejemplo, métricas estándar en cualquier modelo de detección/clasificación). Las métricas pueden incluir cualquiera o todo lo siguiente:

- Matriz de confusión (FP, FN, TP, TN)
- Características de funcionamiento del receptor
- Área bajo la curva
- 45 Fallo previsto -> Fallido: Verdadero Positivo
- Fallo previsto -> No fallido: Falso positivo
- Sin fallo previsto -> No fallido: Verdadero negativo
- Sin fallo previsto -> Fallido: Falso negativo

50 Ejemplos de las métricas pueden incluir lo siguiente:

Sensibilidad, Recuperación, Tasa de aciertos o Tasa de verdaderos positivos (TPR):

$$TPR = TP/P = TP/(TP+FN)$$

55 Especificidad o Tasa de verdaderos negativos (TNR)

$$TNR = TN/N = TN/(TN+FP)$$

60 Precisión o valor predictivo positivo (PPV)

$$PPV = TP/(TP+FP)$$

Valor predictivo negativo (VPN)

65 
$$NPV = TN/(TN+FN)$$

## ES 2 987 306 T3

Tasa de fallos o Tasa de falsos negativos (FNR)

$$FNR = FN/P = FN/(FN+TP) = 1 - TPR$$

5

Fuera de intervalo o Tasa de falsos negativos (FNR)

$$FPR = FP/N = FP/(FP+TN) = 1 - TNR$$

10 Tasa de descubrimiento falso (FDR)

$$FDR = FP/(FP+TP) = 1 - PPV$$

Tasa de omisión falsa (FOR)

15

$$FOR = FN/(FN+TN) = 1 - NPV$$

Precisión (ACC)

20

$$ACC = (TP+TN)/(P+N) = (TP+TN)/(TP+TN+FP+FN)$$

La puntuación F1 es la media armónica de precisión y sensibilidad:

$$F_1 = 2 \cdot \frac{PPV \cdot TPR}{PPV + TPR} = \frac{2TP}{2TP + FP + FN}$$

25

El coeficiente de correlación de Matthews (MCC) es:

$$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}}$$

30 La información o información del impresor de libros (BM) es:

$$BM = TPR + TNR - 1$$

La marca (MK) es

35

$$MK = PPV + NPV - 1$$

En un ejemplo, la precisión o el valor predictivo positivo de un modelo de predicción de fallos puede indicar que, de cuatro alertas, tres alertas son casos de fallo verdadero y una alerta es un caso de fallo falso que conduce a una precisión del 75 %. En otras palabras, si alguien envía una tripulación basándose en esta alarma, tres veces resultará en un mantenimiento preventivo de cualquier tiempo de inactividad de la turbina.

40

En diferentes realizaciones, el módulo de evaluación de modelo 508 determina un área característica de operador de receptor bajo la curva (ROC AUC) para ayudar en la evaluación de rendimiento de modelo. El área característica operativa bajo la curva es una medida del rendimiento del clasificador en el aprendizaje automático. Cuando se usan unidades normalizadas, el área bajo la curva es igual a la probabilidad de que un clasificador clasifique una instancia positiva elegida aleatoriamente más alta que una negativa elegida aleatoriamente (suponiendo que 'positivo' clasifique más alto que 'negativo').

45

El módulo de evaluación de modelo 508 puede probar los diferentes modelos de predicción de fallos de diferentes tiempos de espera y tiempos en retrospectiva y comparar las diferentes evaluaciones para identificar un modelo preferido. La Figura 8 representa un análisis de curvatura que se puede hacer para cualquiera o todas las métricas de rendimiento. En el análisis de curvatura, cada bola en el gráfico tridimensional es una evaluación separada del mismo modelo que usa diferentes tiempos de espera y en retrospectiva e identifica el valor de sensibilidad para cada evaluación.

50

55

En un ejemplo, el módulo de evaluación de modelo 508 evaluó diferentes modelos de predicción de fallos de diferentes tiempos en retrospectiva y de espera:

Tiempo en retrospectiva	Tiempo de espera	AUC de entrenamiento	Sensibilidad de entrenamiento	Precisión de entrenamiento	Especificidad de entrenamiento
31	1	71 %	54 %	63 %	69 %
33	3	92 %	83 %	83 %	83 %

- 5 Con el aumento del tiempo de espera de 1 a 3 días y la ventana de tiempo de observación consistente de 30 días (tiempo en retrospectiva - tiempo de espera), se mejoran todas las métricas de medida de rendimiento. De esta manera, el módulo de evaluación de modelo 508 puede seleccionar un modelo de predicción de fallos con el tiempo en retrospectiva de 33 días y el tiempo de espera de 3 días como la configuración para aplicar nuevos datos para predecir futuros fallos.
- 10 En diferentes realizaciones, la curvatura de rendimiento puede evaluarse para ayudar en la selección de un modelo de predicción de fallos preferido. La búsqueda de rendimiento proporciona un resultado de pronóstico esperado para un tiempo en retrospectiva y de espera dados. La búsqueda de rendimiento proporciona una retrospectiva y un tiempo de espera razonables que un operador puede esperar (por ejemplo, si un operador desea que la sensibilidad del modelo sea superior al 50 %, la curvatura proporcionará tiempo en retrospectiva necesario y de espera apropiado). Como resultado, la búsqueda de rendimiento proporciona un modelo de predicción de fallos claro y completo para modelar la evaluación del rendimiento para todas las opciones posibles (por ejemplo, posibilitando así una selección de un modelo de predicción de fallos para cada conjunto de modelos de predicción de fallos).
- 15 En diferentes realizaciones, el módulo de evaluación de modelo 508 puede generar la curvatura de rendimiento, incluyendo los tiempos en retrospectiva y de espera para permitir que un usuario o dispositivo autorizado seleccione un punto a lo largo de la curvatura de rendimiento para identificar y seleccionar un modelo con un resultado de pronóstico esperado.
- 20 El módulo de evaluación de modelo 508 está configurado para proporcionar la curvatura de rendimiento, cualquier número de modelos de predicción de fallos de un conjunto de modelos de predicción de fallos para un componente o conjunto de componentes, evaluaciones de los modelos de predicción de fallos de un conjunto, la comparación de las evaluaciones y similares con una entidad autorizada para hacer una selección de un modelo de predicción de fallos. Puede haber cualquier número de modelos seleccionados, siendo cada uno de los modelos seleccionados para un componente diferente, tipo de componente, grupos de componentes, grupos de tipo de componente, activo y/o tipo de activo.
- 25 En diferentes realizaciones, el módulo de aplicación de modelo 510 puede comparar nuevos datos de sensor con estados clasificados y/o categorizados identificados por el modelo seleccionado para identificar cuándo los datos de sensor indican un estado de fallo o se alcanza un estado asociado con un fallo potencial. En algunas realizaciones, el módulo de aplicación de modelo 510 puede puntuar la probabilidad o confianza de que se alcance tal estado. El módulo de aplicación de modelo 510 puede comparar la confianza o puntuación frente a un umbral para desencadenar una alerta o informe. En otro ejemplo, el módulo de aplicación de modelo 510 puede comparar el ajuste de los datos de sensor con un estado de fallo o estado asociado con un fallo potencial que ha sido identificado por el modelo del módulo de aplicación de modelo 510 para activar o no activar una alerta o informe.
- 30 El módulo de activación 512 puede establecer umbrales para diferentes componentes, tipos de componentes, grupos de componentes, grupos de tipos de componentes, activos y/o tipos de activos. Cada umbral puede compararse con una salida de uno o más modelos seleccionados. Los umbrales pueden establecerse basándose en el rendimiento del modelo seleccionado para proporcionar una alarma basándose en la probabilidad (por ejemplo, confianza) de predicción, gravedad del fallo, gravedad del efecto potencial del fallo (por ejemplo, infraestructura o vida amenazada), tiempo de espera del fallo y/o similares.
- 35 Se apreciará que puede haber diferentes estados categorizados identificados durante el entrenamiento del modelo. Cada estado categorizado puede estar asociado con un tipo diferente de fallo que incluye el modo de fallo, componente de fallo y/o similares.
- 40 El módulo de generación de informes y alertas 514 puede generar una alerta basándose en la evaluación del módulo de evaluación 614. Una alerta puede ser un mensaje que indica un fallo o tipo de fallo, así como el activo de energía renovable específico (por ejemplo, turbina eólica o panel solar) que puede estar en riesgo de fallo. Dado que el estado identificado por el modelo de predicción de fallos es un estado que está antes de un fallo potencial, la alerta debe activarse antes del fallo potencial de modo que pueda tener lugar una acción correctiva. En algunas realizaciones, se pueden generar diferentes alertas basándose en diferentes posibles fallos y/o diferentes estados de fallo. Por ejemplo, algunos estados de fallo pueden ser más graves que otros, ya que se pueden proporcionar más alertas y/o alertas detalladas adicionales para un mayor número de dispositivos digitales (por ejemplo, teléfonos celulares, operadores, empresas de servicios públicos, ordenadores de servicio o similares) dependiendo de la gravedad, importancia y/o inminencia del fallo.
- 45 En algunas realizaciones, el módulo de generación de informes y alertas 514 puede generar un informe que indica cualquier número de fallos potenciales, la probabilidad de tal fallo y la justificación o razonamiento basándose en el modelo y el ajuste de estados previamente identificados asociados con fallos futuros de componentes.
- 50 El almacenamiento de datos 516 puede ser cualquier tipo de almacenamiento de datos que incluye bases de datos de tablas o similares. El almacenamiento de datos 516 puede almacenar modelos, datos históricos, datos de sensor
- 55
- 60
- 65

actuales, estados que indican un posible fallo futuro, alertas, informes y/o similares.

Un módulo puede ser hardware (por ejemplo, circuitería y/o chip programable), software, o una combinación de hardware y software.

5 La Figura 9 es un diagrama de flujo para predecir fallos y/o fallos potenciales de activos de energía renovable. En el ejemplo de la Figura 9, se analizan los fallos de predicción y/o los fallos potenciales de las turbinas eólicas. En la etapa 902, el módulo de comunicación 502 recibe los datos de sensor históricos de cualquier número de componentes de cualquier número de activos eléctricos. En diferentes realizaciones, el sistema de predicción de fallos de componentes  
10 puede generar cualquier número de diferentes modelos de predicción de fallos para un conjunto de modelos de predicción de fallos, siendo cada conjunto de modelos de predicción de fallos para cada componente, grupo de componentes, tipo de componente, tipo de grupo de componentes y/o similares. Cada conjunto de modelos de predicción de fallos del conjunto de modelos de predicción de fallos puede variar en términos de la ventana de observación (por ejemplo, limitado a una ventana predeterminada de los datos históricos usados para entrenar un modelo) y/o tiempo de espera.  
15

En la etapa 904, el módulo de preparación de datos de entrenamiento 504 puede normalizar y/o extraer características (por ejemplo, derivadas o no derivadas) de los datos de sensor históricos recibidos. Se apreciará que, en algunas realizaciones, el módulo de preparación de datos de entrenamiento 504 puede determinar la ventana de observación para que se entrene un modelo, extraer o recibir los datos de sensor históricos que se generaron durante la ventana de observación, y reducir la dimensionalidad de los datos (por ejemplo, usando análisis de componentes principales) y/o extraer características (por ejemplo, columnas o métricas) a partir de los datos de sensor históricos para entrenar uno o más modelos de predicción de fallos del conjunto.  
20

En la etapa 906, el módulo de entrenamiento de modelo 506 entrena cualquier número de modelos de predicción de fallos de un conjunto usando diferentes ventanas de observación de los datos de sensor históricos y/o tiempos de espera para cada modelo diferente del mismo componente, grupo de componentes, tipo de componente, tipo de grupo de componentes y/o similares. El módulo de entrenamiento de modelo 506 puede utilizar agrupamiento de k-medias, redes neuronales, bosques aleatorios o similares.  
25  
30

En la etapa 908, el módulo de evaluación de modelo 508 puede evaluar cada modelo de predicción de fallos de un conjunto de modelos de predicción de fallos. Por ejemplo, el módulo de evaluación de modelo 508 puede evaluar cada modelo que predice el fallo de un generador de una turbina eólica. Cada modelo del conjunto puede variar dependiendo de la ventana de observación y la ventana de tiempo de espera usada en la generación del modelo.  
35

El módulo de evaluación de modelo 508 puede utilizar métricas normalizadas como se analiza en el presente documento para evaluar los modelos del conjunto de modelos. El módulo de evaluación de modelo 508 puede utilizar cualquiera o todas las siguientes métricas que incluyen, pero sin limitación, Sensibilidad, Recuperación, Tasa de aciertos, o tasa de verdaderos positivos (TPR), Especificidad o Tasa de verdaderos negativos (TNR), Precisión o valor predictivo positivo (PPV), Valor predictivo negativo (VPN), Tasa de fallos o Tasa de falsos negativos (FNR), Fuera de intervalo o Tasa de falsos negativos (FNR), Tasa de descubrimiento falso (FDR), Tasa de omisión falsa (FOR), Precisión (ACC), la puntuación F1 es la media armónica de precisión y sensibilidad, el coeficiente de correlación de Matthews (MCC), la información o información del impresor de libros (BM), la marca (MK) y/o el área bajo la curva (AUC).  
40  
45

En la etapa 910, el módulo de evaluación de modelo 508 puede comparar cualquier número de las evaluaciones de modelo de modelos de predicción de fallos de un conjunto de modelos de predicción de fallos con cualquiera del otro conjunto de evaluaciones de modelo para seleccionar un modelo preferido del conjunto de modelos. Por ejemplo, dos modelos de predicción de fallos diferentes de un conjunto con diferente tiempo en retrospectiva (por ejemplo, 31 y 33 días, respectivamente) y diferentes tiempos de espera (por ejemplo, 1 y 3 días, respectivamente) pueden tener diferentes AUC (71 % y 92 %, respectivamente), diferente sensibilidad de entrenamiento (54 % y 83 %, respectivamente), precisión de entrenamiento diferente (63 % y 83 %, respectivamente) y especificidad de entrenamiento (69 % y 83 %, respectivamente). Se apreciará que cada modelo de predicción de fallos de un conjunto puede compararse usando métricas similares y/o métricas diferentes como se ha descrito anteriormente. Basándose en los dos modelos de predicción de fallos diferentes en este ejemplo, el módulo de evaluación de modelo 508 o la entidad autorizada puede seleccionar el modelo de predicción de fallos con el tiempo de espera más largo, mayor AUC, sensibilidad de entrenamiento, precisión de entrenamiento y especificidad de entrenamiento incluso aunque el tiempo en retrospectiva sea mayor.  
50  
55

En la etapa 912, el módulo de aplicación de modelo 510 puede recibir datos de sensor actuales de los mismos componentes o grupo de componentes que proporcionaron los datos de sensor históricos. El módulo de aplicación de modelo 510 puede aplicar el modelo de predicción de fallos seleccionado a los datos de sensor actuales para generar una predicción.  
60

En la etapa 914, el módulo de activación 512 puede comparar la salida del modelo de predicción de fallos seleccionado con un umbral para determinar si se cumplen las condiciones de activación 914. En otras palabras, el módulo de  
65

5 activación 512 puede comparar una probabilidad de precisión o confianza de un fallo previsto con un umbral de predicción de fallos. En diferentes realizaciones, el módulo de activación 512 puede almacenar activaciones de umbral en una base de datos de activación de umbral. Puede haber diferentes umbrales de activación para diferentes componentes, tipos de componentes, grupos de componentes, grupos de tipos de componentes, activos y/o tipos de activos. En diferentes realizaciones, puede haber diferentes umbrales de activación dependiendo de la cantidad de daño que puede causarse al activo por fallo, a otros activos por fallo, a la red eléctrica, a la infraestructura, a la propiedad y/o vida. Puede haber diferentes umbrales de activación basados en el modelo seleccionado (por ejemplo, basados en la sensibilidad, precisión, cantidad de tiempo de espera, tiempo previsto de fallo y/o similares). Los diferentes umbrales de activación pueden establecerse, en algunas realizaciones, por una compañía eléctrica, individuo autorizado, dispositivo digital autorizado y/o similares.

15 En la etapa 916, el módulo de generación de informes y alertas 514 puede generar una alerta si se satisface una condición de activación. En algunas realizaciones, el módulo de generación de informes y alertas 514 puede tener un umbral de alerta que debe activarse antes de que se emita la alerta. Por ejemplo, el umbral de alerta puede basarse en la cantidad de daño que puede causarse al activo por fallo, a otros activos por fallo, a la red eléctrica, a la infraestructura, a la propiedad y/o vida. La alerta puede emitirse por mensaje de texto, SMS, correo electrónico, mensaje instantáneo, llamada telefónica y/o similares. La alerta puede indicar el componente, grupo de componentes, tipo de componente, tipo de grupo de componentes y/o similares que desencadenaron la predicción, así como cualquier información relevante para la predicción, como porcentaje de confianza y marco de tiempo previsto.

20 En diferentes realizaciones, se genera un informe que puede indicar cualquier número de fallos previstos de cualquier número de componentes o grupos de componentes basándose en la aplicación de modelos seleccionados a diferentes datos de sensor que pueden permitir que el sistema proporcione una mayor comprensión de la salud del sistema.

25 En algunas realizaciones, el módulo de evaluación 508 puede evaluar métricas basadas en costes de cada modelo de un conjunto de modelos para el mismo componente, grupo de componentes, tipo de componente, tipo de grupo de componentes y/o similares. Por ejemplo, el módulo de evaluación de modelo 508 puede evaluar cada modelo que predice el fallo de un generador de una turbina eólica y el efecto sobre el coste. Cada modelo del conjunto puede variar dependiendo de la ventana de observación y la ventana de tiempo de espera usada en la generación del modelo.

30 El módulo de evaluación de modelo 508 puede utilizar métricas de coste normalizadas para evaluar los modelos de predicción de fallos de un conjunto de modelos de predicción de fallos. Estas pueden incluir:

- 35 Coste promedio de reparación preventiva (AFC)
- Coste promedio de ejecución a fallo (ARFC)
- Coste promedio por visita innecesaria (ACUV)

Un modelo de coste de referencia (BCM) puede incluir:

40  $\text{Costo de operación tal como está de (AC)} = \text{Número de casos de fallo} * \text{ARFC} + \text{Número de casos de reparación preventiva} * \text{AFC} + \text{Número de casos de visita innecesaria} * \text{ACUV}$

Un modelo de coste objetivo puede incluir:

45  $\text{Costo de mantenimiento predictivo (PMC)} = \text{Número de casos de fallo} * \text{ARFC} + \text{Número de casos de reparación preventiva} * \text{AFC} + \text{Número de casos de visita innecesaria} * \text{ACUV}$

50 El módulo de evaluación de modelo 508 puede comparar las métricas de coste normalizadas de cualquier número de modelos de predicción de fallos de un conjunto de modelos de predicción de fallos entre sí para seleccionar o ayudar en la selección de una predicción de fallos de modelo del conjunto. En diferentes realizaciones, el módulo de evaluación de modelo 508 utiliza tanto las métricas de rendimiento estandarizadas analizadas en el presente documento como las métricas de coste estandarizadas al comparar diferentes modelos y seleccionar un modelo de cualquier número de las comparaciones.

55 La Figura 10 representa un cálculo de un coste de mantenimiento predictivo de ejemplo en un ejemplo. En la Figura 10, el número de casos de fallo puede ser una tasa de falsos negativos multiplicada por el número total de casos. El número de casos de arreglos preventivos puede ser una tasa positiva verdadera multiplicada por el número total de casos. El número de casos de visitas innecesarias puede ser una tasa de falsos positivos multiplicada por el número total de casos.

60 La Figura 11 es un gráfico de una optimización adicional del análisis de rendimiento por coste en algunas realizaciones. En algunas realizaciones, un entrenador de modelos puede desear publicar un modelo para predecir un fallo particular de un componente. El entrenador puede usar ahorros de costes objetivo del entrenamiento de modelo. En este caso. Un punto en la figura (por ejemplo, el punto con flechas que van desde el tiempo retrospectivo y el tiempo de espera es el punto de ahorro de costes objetivo. A partir de esta caracterización, el entrenador puede publicar un modelo con un cierto tiempo de espera y en retrospectiva.

La figura 11 representa un coste de mantenimiento predictivo (PMC) a lo largo de un eje vertical, un tiempo de espera a lo largo de un eje horizontal y un tiempo en retrospectiva a lo largo del eje z. A través de este eje diferente y la comparación de diferentes modelos usando este gráfico, se puede utilizar una optimización de costes preferida para seleccionar uno o más modelos.

En diferentes realizaciones, el módulo de activación 512 puede comparar modelos aplicados a datos actuales con umbrales basándose en el coste, así como en el rendimiento. De esta manera, las alertas pueden generarse basándose en un análisis de costes (por ejemplo, el impacto de un fallo en un mayor costo, incluso si la probabilidad es moderada, aún puede ser motivo para generar una alerta de mantenimiento preventivo).

La Figura 12 representa un diagrama de bloques de un servidor de sistema informático de ejemplo 1200 de acuerdo con algunas realizaciones. El servidor de sistema informático 1200 se muestra en forma de un dispositivo informático de propósito general. El servidor de sistema informático 1200 incluye el procesador 1202, RAM 1204, interfaz de comunicación 1206, dispositivo de entrada/salida 1208, almacenamiento 1210 y un bus de sistema 1212 que acopla diversos componentes de sistema, incluido el almacenamiento 1210 al procesador 1202.

El bus de sistema 1212 representa uno o más de cualquiera de varios tipos de estructuras de bus, incluyendo un bus de memoria o controlador de memoria, un bus periférico, un puerto de gráficos acelerado y un procesador o bus local que usa cualquiera de una variedad de arquitecturas de bus. A modo de ejemplo, y sin limitación, tales arquitecturas incluyen bus de Arquitectura Estándar de la Industria (ISA), bus de arquitectura de microcanal (MCA), bus ISA mejorado (EISA), el bus local de la Asociación de Normas de Electrónica de Vídeo (VESA) y el bus de Interconexión de Componentes Periféricos (PCI).

El servidor de sistema informático 1200 incluye normalmente una diversidad de medios legibles de sistema informático. Dichos medios pueden ser cualquier medio disponible que sea accesible por el sistema de mitigación de congestión 1204 e incluye tanto medios volátiles como no volátiles, medios extraíbles y no extraíbles.

En algunas realizaciones, el procesador 1202 está configurado para ejecutar instrucciones ejecutables (por ejemplo, programas). En algunas realizaciones, el procesador 1004 comprende circuitería o cualquier procesador capaz de procesar las instrucciones ejecutables.

En algunas realizaciones, la RAM 1204 almacena datos. En diferentes realizaciones, los datos de trabajo se almacenan dentro de la RAM 1206. Los datos dentro de la RAM 1206 pueden borrarse o transferirse finalmente al almacenamiento 1210.

En algunas realizaciones, la interfaz de comunicación 1206 está acoplada a una red a través de la interfaz de comunicación 1206. Tal comunicación puede tener lugar a través del dispositivo de Entrada/Salida (E/S) 1208. Aún más, el sistema de mitigación de congestión 1204 puede comunicarse con una o más redes tales como una red de área local (LAN), una red de área extensa general (WAN) y/o una red pública (por ejemplo, la Internet).

En algunas realizaciones, el dispositivo de entrada/salida 1208 es cualquier dispositivo que introduce datos (por ejemplo, ratón, teclado, lápiz óptico) o emite datos (por ejemplo, altavoz, pantalla, casco de realidad virtual).

En algunas realizaciones, el almacenamiento 1210 puede incluir medios legibles por sistema informático en forma de memoria volátil, tal como memoria de solo lectura (ROM) y/o memoria caché. El almacenamiento 1210 puede incluir además otros dispositivos extraíbles/no extraíbles, medios de almacenamiento de sistema informático volátiles/no volátiles. Únicamente a modo de ejemplo, el almacenamiento 1210 se puede proporcionar para leer y escribir en un dispositivo no extraíble, medios magnéticos no volátiles (no mostrados y normalmente denominados "disco duro"). Aunque no se muestra, una unidad de disco magnético para leer y escribir en un dispositivo extraíble, disco magnético no volátil (por ejemplo, un "disco flexible") y una unidad de disco óptico para leer o escribir en un dispositivo extraíble, disco óptico no volátil tal como un CDROM, DVD-ROM u otros medios ópticos se pueden proporcionar. En dichos casos, cada uno puede conectarse al bus de sistema 1212 mediante una o más interfaces de medios de datos. Como se describirá adicionalmente más adelante, el almacenamiento 1210 puede incluir al menos un producto de programa que tiene un conjunto (por ejemplo, al menos uno) de módulos de programa que están configurados para llevar a cabo las funciones de las realizaciones de la invención. En algunas realizaciones, la RAM 1204 se encuentra dentro del almacenamiento 1210.

El programa/utilidad, que tiene un conjunto (al menos uno) de módulos de programa, tal como el sistema de mitigación de congestión 1204, puede almacenarse en el almacenamiento 1210 a modo de ejemplo, y sin limitación, así como en un sistema operativo, uno o más programas de aplicación, otros módulos de programa y datos de programa. Cada uno del sistema operativo, uno o más programas de aplicación, otros módulos de programa y datos de programa o alguna combinación de los mismos, puede incluir una implementación de un entorno de red. Los módulos de programa generalmente llevan a cabo las funciones y/o metodologías de las realizaciones de la invención como se describe en el presente documento.

Debe entenderse que, aunque no se muestra, otros componentes de hardware y/o software podrían usarse junto con el sistema de mitigación de congestión 1204. Ejemplos, incluyen, pero sin limitación: microcódigos, controladores de dispositivo, unidades de procesamiento redundantes y matrices de unidades de disco externas, sistemas RAID, unidades de cinta y sistemas de almacenamiento de archivo de datos, etc.

5 Las realizaciones ilustrativas se describen en el presente documento en detalle con referencia a los dibujos adjuntos. Sin embargo, la presente divulgación puede implementarse de diversas maneras y, por tanto, no debe interpretarse que se limita a las realizaciones divulgadas en el presente documento. Por el contrario, esas realizaciones se proporcionan para la comprensión exhaustiva y completa de la presente divulgación, y para transmitir completamente el alcance de la presente divulgación a los expertos en la materia.

15 Como será apreciado por un experto en la materia, los aspectos de una o más realizaciones pueden materializarse como un sistema, método o producto de programa informático. En consecuencia, algunos aspectos pueden adoptar la forma de una realización completamente de hardware, una realización completamente de software (incluyendo firmware, software residente, microcódigo, etc.) o una realización que combine aspectos de software y hardware que en el presente documento se puedan denominar, por lo general, "circuito", "módulo" o "sistema". Asimismo, algunos aspectos pueden adoptar la forma de un producto de programa informático incorporado en uno o más medio(s) legible(s) por ordenador que tiene(n) un código de programa legible por ordenador incorporado en los mismos.

20 Puede utilizarse cualquier combinación de uno o más medios legibles por ordenador. El medio legible por ordenador puede ser un medio de señal legible por ordenador o un medio de almacenamiento legible por ordenador. Un medio de almacenamiento legible por ordenador puede ser, por ejemplo, pero sin limitación, un sistema, aparato, o dispositivo electrónico, magnético, óptico, electromagnético, de infrarrojos o semiconductores, o cualquier combinación apropiada de los anteriores. Entre los ejemplos más específicos del medio de almacenamiento legible por ordenador (una lista sin carácter exhaustivo) se incluirían los siguientes: una conexión eléctrica con uno o más cables, un disquete informático portátil, un disco duro, una memoria de acceso aleatorio (RAM), una memoria de solo lectura (ROM), una memoria de solo lectura programable y borrable (EPROM o memoria flash), una fibra óptica, un disco compacto-memoria de solo lectura portátil (CD-ROM), un dispositivo de almacenamiento óptico, un dispositivo de almacenamiento magnético o cualquier combinación apropiada de los anteriores. En el contexto de este documento, un medio de almacenamiento legible por ordenador puede ser cualquier medio tangible que puede contener o almacenar un programa para su uso con, o junto con, un sistema, aparato o dispositivo de ejecución de instrucciones.

35 Un medio de señal legible por ordenador puede incluir una señal de datos propagada con un código de programa legible por ordenador incorporado en este, por ejemplo, en la banda base o como parte de una onda portadora. Dicha señal propagada puede adoptar cualquiera de una variedad de formas, incluyendo, pero sin limitación, electromagnético, óptico o cualquier combinación adecuada de los mismos. Un medio de señal legible por ordenador puede ser cualquier medio legible por ordenador que no sea un medio de almacenamiento legible por ordenador y que pueda transmitir, propagar o transportar un programa para su uso con, o junto con, un sistema, aparato o dispositivo de ejecución de instrucciones.

40 El código de programa incorporado en un medio legible por ordenador puede transmitirse usando cualquier medio apropiado, incluyendo, pero sin limitación: de manera inalámbrica, por cable, por cable de fibra óptica, por RF, etc., o mediante cualquier combinación apropiada de los anteriores.

45 El código de programa informático para llevar a cabo las operaciones de aspectos de la presente invención puede escribirse en cualquier combinación de uno o más lenguajes de programación, incluyendo un lenguaje de programación orientado a objetos, como Java, Smalltalk, C++ u otro similar, y lenguajes de programación de procedimientos convencionales, tal como el lenguaje de programación "C" u otros lenguajes de programación similares. El código de programa puede ejecutarse completamente en el ordenador del usuario, parcialmente en el ordenador del usuario, como paquete de *software* independiente, parcialmente en el ordenador del usuario y parcialmente en un ordenador remoto, o completamente en el ordenador remoto o servidor. En el último caso, el ordenador remoto puede estar conectado al ordenador del usuario a través de cualquier tipo de red, incluyendo una red de área local (LAN) o red de área amplia (WAN), o la conexión se puede realizar con un ordenador externo (por ejemplo, a través de internet, utilizando un proveedor de servicios de internet).

55 Algunos aspectos de la presente invención se describen a continuación con referencia a ilustraciones de diagramas de flujo y/o diagramas de bloques de métodos, aparato (sistemas) y productos de programas informáticos de acuerdo con realizaciones de la invención. Se entenderá que cada bloque de las ilustraciones de diagramas de flujo y/o diagramas de bloques, y las combinaciones de bloques en las ilustraciones de diagramas de flujo y/o diagramas de bloque, pueden implementarse mediante instrucciones de programa informático. Estas instrucciones de programa informático se pueden proporcionar a un procesador de un ordenador de propósito general, un ordenador de propósito especial u otros aparatos de procesamiento de datos programables para producir una máquina, de modo que las instrucciones, que se ejecutan a través del procesador del ordenador u otro aparato de procesamiento de datos programable, crean medios para implementar las funciones/acciones especificadas en el bloque o bloques de diagrama de flujo y/o de diagrama de bloques.

Estas instrucciones de programa informático también se pueden almacenar en un medio legible por ordenador que pueda hacer que un ordenador, otro aparato de procesamiento de datos programable u otros dispositivos funcionen de una forma en particular, de modo que las instrucciones almacenadas en el medio legible por ordenador producen un artículo de fabricación que incluye instrucciones que implementan la función/acción especificada en el bloque o bloques del flujograma y/o diagrama de bloques.

5

Las instrucciones de programa informático también pueden cargarse en un ordenador, otro aparato de procesamiento de datos programable u otros dispositivos, para así hacer que se lleven a cabo una serie de etapas operacionales en el ordenador, otro aparato programable u otros dispositivos, para así elaborar un proceso implementado por ordenador y que las instrucciones que se ejecutan en el ordenador u otro aparato programable proporcionen procesos para implementar las funciones/acciones especificadas en el bloque o bloques del flujograma y/o diagrama de bloques.

10

REIVINDICACIONES

1. Un medio legible por ordenador no transitorio que comprende instrucciones ejecutables, pudiendo las instrucciones ejecutables ejecutarse por uno o más procesadores para realizar un método, comprendiendo el método:

5 recibir primeros datos de sensor históricos de un primer período de tiempo, incluyendo los primeros datos de sensor históricos datos de sensor de uno o más sensores de uno o más componentes de cualquier número de activos de energía renovable, indicando los primeros datos de sensor históricos al menos un primer fallo asociado con el uno o más componentes del activo de energía renovable durante el primer período de tiempo;

10 generar un primer conjunto de modelos de predicción de fallos usando los primeros datos de sensor históricos, entrenándose cada uno del primer conjunto de modelos de predicción de fallos por diferentes cantidades de primeros datos de sensor históricos basándose en diferentes ventanas de tiempo de observación y diferentes ventanas de tiempo de espera, incluyendo cada ventana de tiempo de observación un período de tiempo durante el cual se generan los primeros datos históricos, incluyendo la ventana de tiempo de espera un período de tiempo antes de un fallo previsto;

15 evaluar cada modelo de predicción de fallos del primer conjunto de modelos de predicción de fallos usando al menos una matriz de confusión que incluye métricas para verdaderos positivos, falsos positivos, verdaderos negativos y falsos negativos, así como un valor de predicción positivo;

20 seleccionar al menos un modelo de predicción de fallos del primer conjunto de modelos de predicción de fallos basándose en la evaluación de las matrices de confusión, los valores de predicción positivos y las ventanas de tiempo de espera para crear un primer modelo de predicción de fallos seleccionado, incluyendo el primer modelo de predicción de fallos seleccionado la ventana de tiempo de espera antes de un fallo previsto;

25 recibir primeros datos de sensor actuales de un segundo período de tiempo, incluyendo los primeros datos de sensor actuales datos de sensor del uno o más sensores del uno o más componentes del activo de energía renovable;

30 aplicar el primer modelo de predicción de fallos seleccionado a los datos de sensor actuales para generar una primera predicción de fallos de un fallo de al menos un componente del uno o más componentes;

comparar la primera predicción de fallos con un primer criterio de activación; y

generar y transmitir una primera alerta basándose en la comparación de la predicción de fallos con los primeros criterios de activación, indicando la alerta el al menos un componente del uno o más componentes e información con respecto a la predicción de fallos.

2. El medio legible por ordenador no transitorio de la reivindicación 1, en donde el activo de energía renovable es una turbina eólica o un panel solar.

3. El medio legible por ordenador no transitorio de la reivindicación 1, en donde cada uno del primer conjunto de modelos de predicción de fallos puede predecir el fallo de un componente del activo de energía renovable.

4. El medio legible por ordenador no transitorio de la reivindicación 3, comprendiendo además el método seleccionar un primer umbral de activación de una pluralidad de umbrales de activación basándose en el componente, en donde cada umbral de activación diferente de la pluralidad de umbrales de activación se dirige a un componente o grupo de componentes diferente.

5. El medio legible por ordenador no transitorio de la reivindicación 3, comprendiendo además el método filtrar los primeros datos de sensor históricos para recuperar una porción de los datos de sensor históricos relacionados con el componente, comprendiendo generar el primer conjunto de modelos de predicción de fallos usando los primeros datos de sensor históricos generar el primer conjunto de modelos de predicción de fallos usando la porción de los primeros datos de sensor históricos.

6. El medio legible por ordenador no transitorio de la reivindicación 3, comprendiendo además el método:

generar un segundo conjunto de modelos de predicción de fallos usando los primeros datos de sensor históricos, entrenándose cada uno del segundo conjunto de modelos de predicción de fallos por diferentes cantidades de primeros datos de sensor históricos basándose en diferentes ventanas de tiempo de observación y diferentes ventanas de tiempo de espera, incluyendo cada ventana de tiempo de observación un período de tiempo durante el cual se generan los primeros datos históricos, incluyendo la ventana de tiempo de espera un período de tiempo antes de un fallo previsto, siendo el segundo conjunto de modelos de predicción de fallos para predecir un fallo de un componente que es diferente del primer conjunto de modelos de predicción de fallos;

evaluar cada modelo de predicción de fallos del segundo conjunto de modelos de predicción de fallos usando al menos la matriz de confusión que incluye métricas para verdaderos positivos, falsos positivos, verdaderos negativos y falsos negativos, así como un valor de predicción positivo;

comparar la matriz de confusión y el valor de predicción positivo de cada uno del segundo conjunto de modelos de predicción de fallos;

seleccionar al menos un modelo de predicción de fallos del segundo conjunto de modelos de predicción de fallos basándose en la comparación de las matrices de confusión, los valores de predicción positivos y las ventanas de tiempo de espera para crear un segundo modelo de predicción de fallos seleccionado, incluyendo el segundo

- modelo de predicción de fallos seleccionado la ventana de tiempo de espera antes de un fallo previsto; recibir primeros datos de sensor actuales de un segundo período de tiempo, incluyendo los primeros datos de sensor actuales datos de sensor del uno o más sensores del uno o más componentes del activo de energía renovable;
- 5 aplicar el segundo modelo de predicción de fallos seleccionado a los datos de sensor actuales para generar una segunda predicción de fallos; comparar la segunda predicción de fallos con un segundo criterio de activación; y generar y transmitir una segunda alerta basándose en la comparación de la predicción de fallos con los segundos criterios de activación, indicando la alerta el al menos un componente del uno o más componentes e información con respecto a la predicción de fallos.
- 10
7. El medio legible por ordenador no transitorio de la reivindicación 6, comprendiendo además el método filtrar los segundos datos de sensor históricos para recuperar una porción de los datos de sensor históricos relacionados con el componente, comprendiendo generar el segundo conjunto de modelos de predicción de fallos usando los primeros datos de sensor históricos generar el segundo conjunto de modelos de predicción de fallos usando la porción de los primeros datos de sensor históricos.
- 15
8. El medio legible por ordenador no transitorio de la reivindicación 1, en donde seleccionar al menos un modelo de predicción de fallos del primer conjunto de modelos de predicción de fallos comprende generar un análisis de curvatura que incluye un indicador para cada modelo de predicción de fallos del primer conjunto de modelos de predicción de fallos en un gráfico usando diferentes ventanas de tiempo de espera y ventanas de tiempo de observación, proporcionando el análisis de curvatura un valor de predicción positivo para cada modelo de predicción de fallos del primer conjunto de modelos de predicción de fallos.
- 20
9. El medio legible por ordenador no transitorio de la reivindicación 8, en donde seleccionar al menos un modelo de predicción de fallos del primer conjunto de modelos de predicción de fallos comprende adicionalmente recibir una selección del modelo de predicción de fallos seleccionado usando el análisis de curvatura desde un dispositivo digital autorizado.
- 25
10. Un sistema, que comprende
- 30 al menos un procesador; y un medio de memoria legible por ordenador no transitorio de acuerdo con cualquiera de las reivindicaciones 1 a 9, pudiendo las instrucciones ejecutables ejecutarse por el al menos un procesador para realizar el método.
- 35
11. Un método que comprende:
- recibir primeros datos de sensor históricos de un primer período de tiempo, incluyendo los primeros datos de sensor históricos datos de sensor de uno o más sensores de uno o más componentes de cualquier número de activos de energía renovable, indicando los primeros datos de sensor históricos al menos un primer fallo asociado con el uno o más componentes del activo de energía renovable durante el primer período de tiempo;
- 40
- generar un primer conjunto de modelos de predicción de fallos usando los primeros datos de sensor históricos, entrenándose cada uno del primer conjunto de modelos de predicción de fallos por diferentes cantidades de primeros datos de sensor históricos basándose en diferentes ventanas de tiempo de observación y diferentes ventanas de tiempo de espera, incluyendo cada ventana de tiempo de observación un período de tiempo durante el cual se generan los primeros datos históricos, incluyendo la ventana de tiempo de espera un período de tiempo antes de un fallo previsto;
- 45
- evaluar cada modelo de predicción de fallos del primer conjunto de modelos de predicción de fallos usando al menos una matriz de confusión que incluye métricas para verdaderos positivos, falsos positivos, verdaderos negativos y falsos negativos, así como un valor de predicción positivo;
- 50
- seleccionar al menos un modelo de predicción de fallos del primer conjunto de modelos de predicción de fallos basándose en la evaluación de las matrices de confusión, los valores de predicción positivos y las ventanas de tiempo de espera para crear un primer modelo de predicción de fallos seleccionado, incluyendo el primer modelo de predicción de fallos seleccionado la ventana de tiempo de espera antes de un fallo previsto;
- 55
- recibir primeros datos de sensor actuales de un segundo período de tiempo, incluyendo los primeros datos de sensor actuales datos de sensor del uno o más sensores del uno o más componentes del activo de energía renovable;
- 60
- aplicar el primer modelo de predicción de fallos seleccionado a los datos de sensor actuales para generar una primera predicción de fallos de un fallo de al menos un componente del uno o más componentes; comparar la primera predicción de fallos con un primer criterio de activación; y generar y transmitir una primera alerta basándose en la comparación de la predicción de fallos con los primeros criterios de activación, indicando la alerta el al menos un componente del uno o más componentes e información con respecto a la predicción de fallos.
- 65

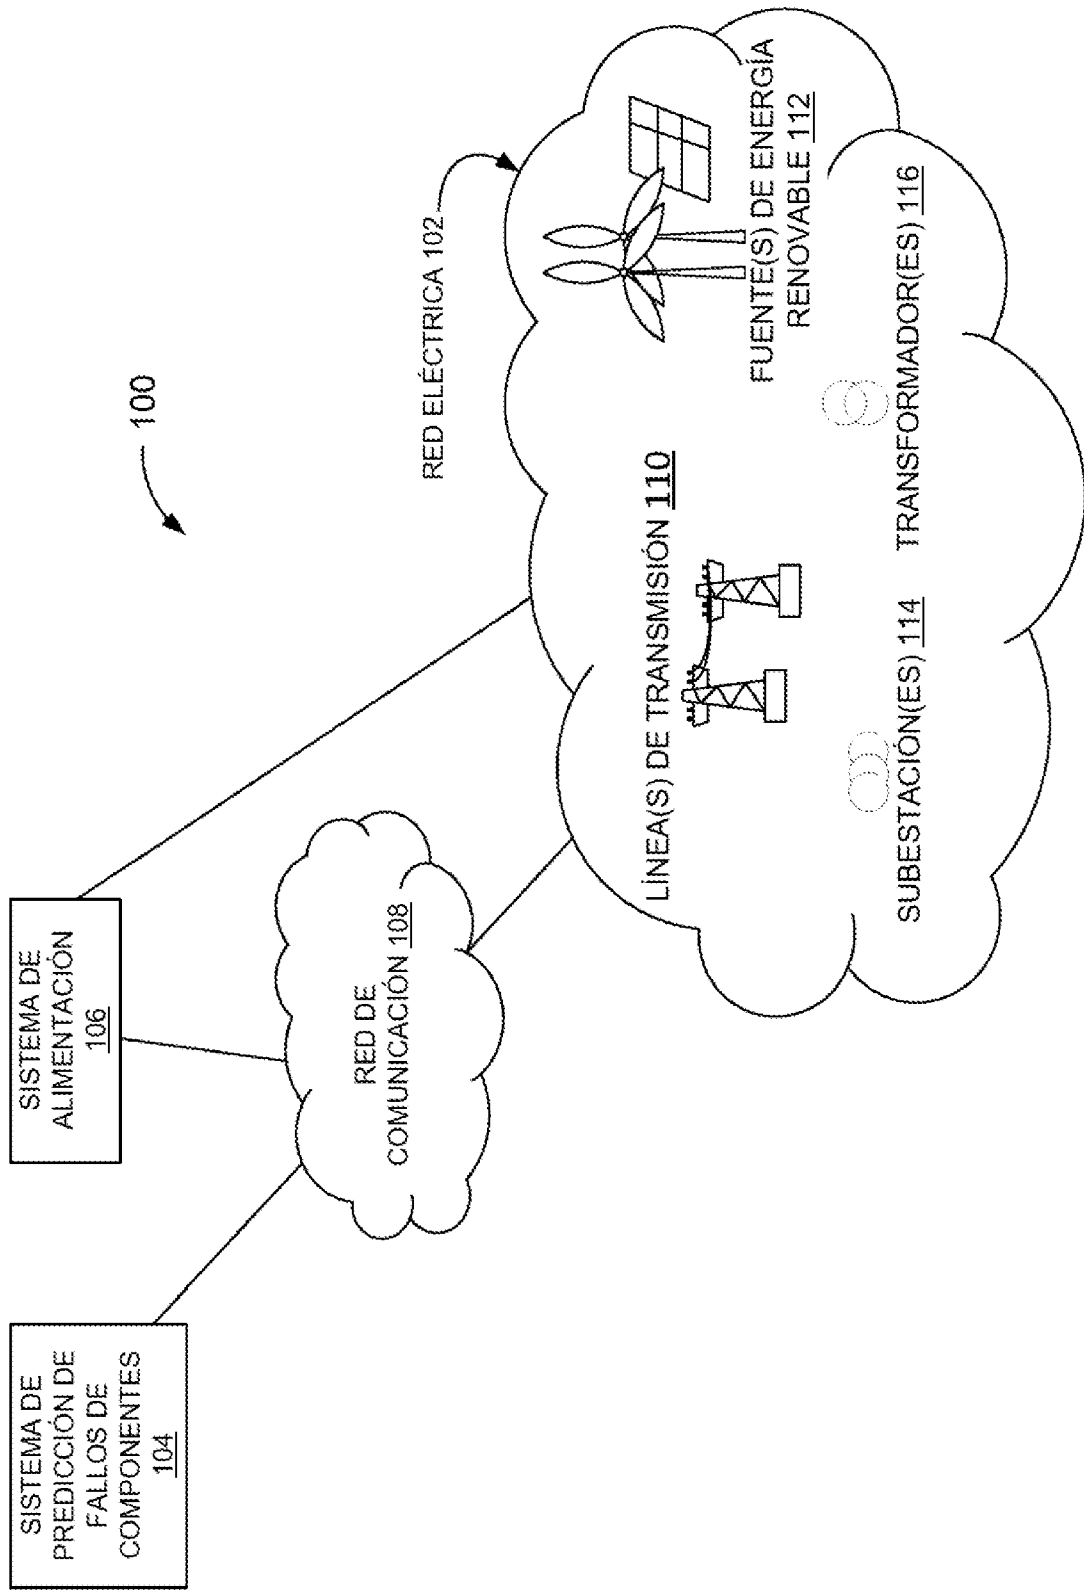


FIG. 1




FIG. 2




FIG. 3

### Enfoque tradicional de predicción de fallos y desafíos

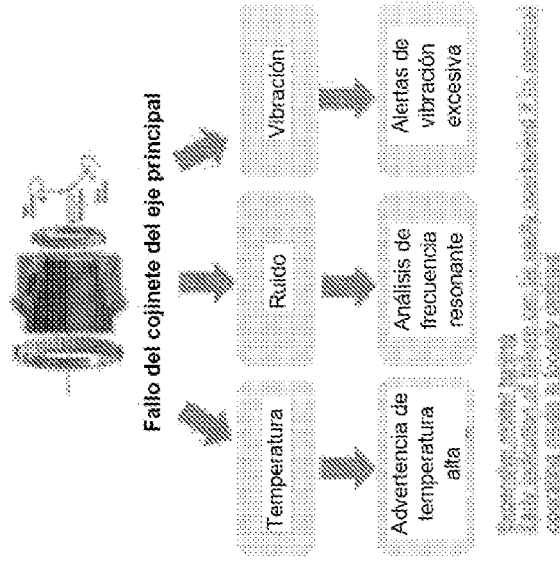



FIG. 4

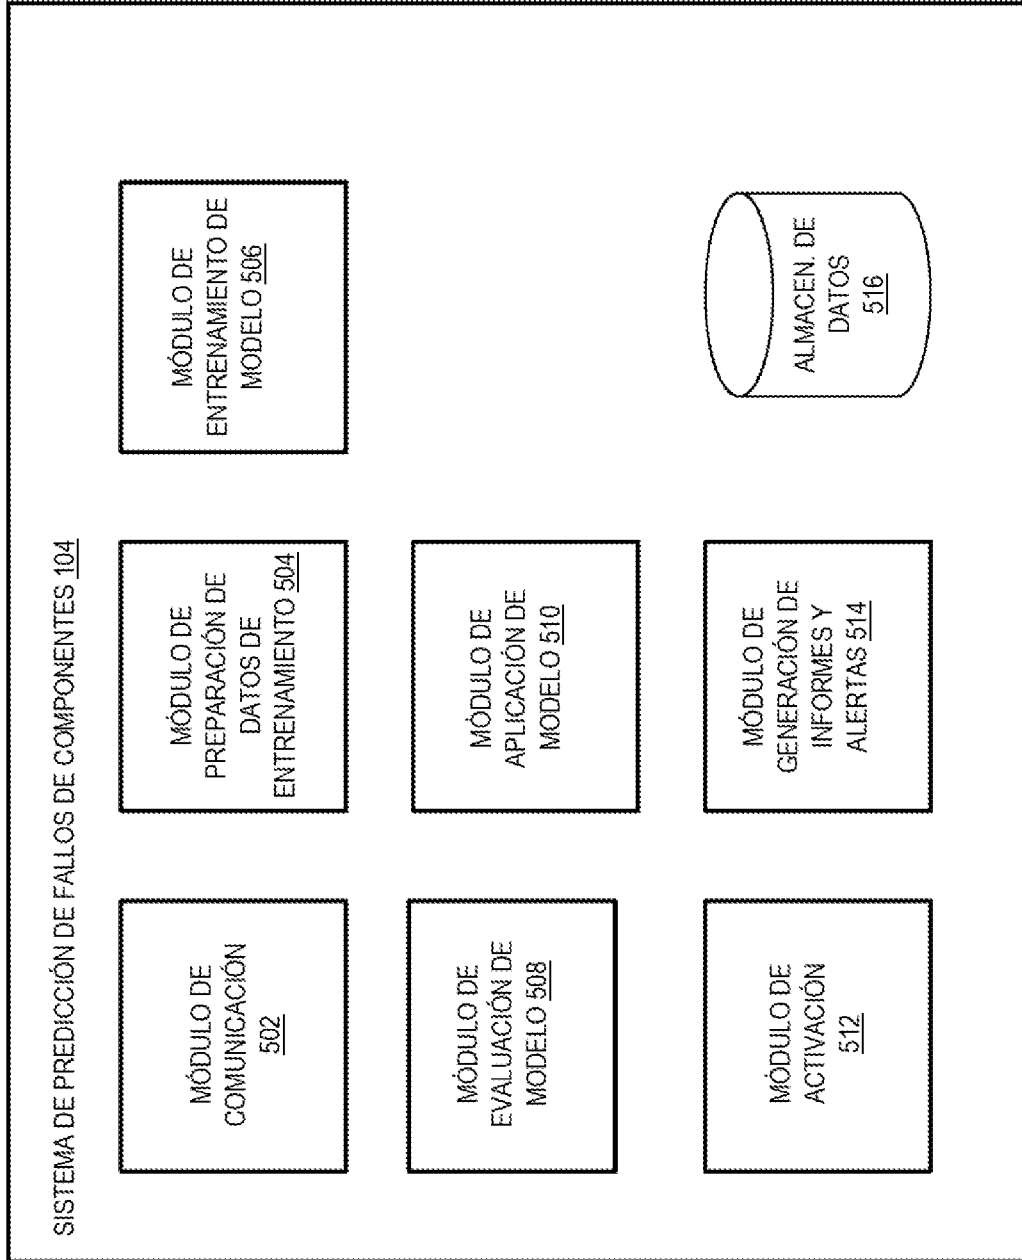
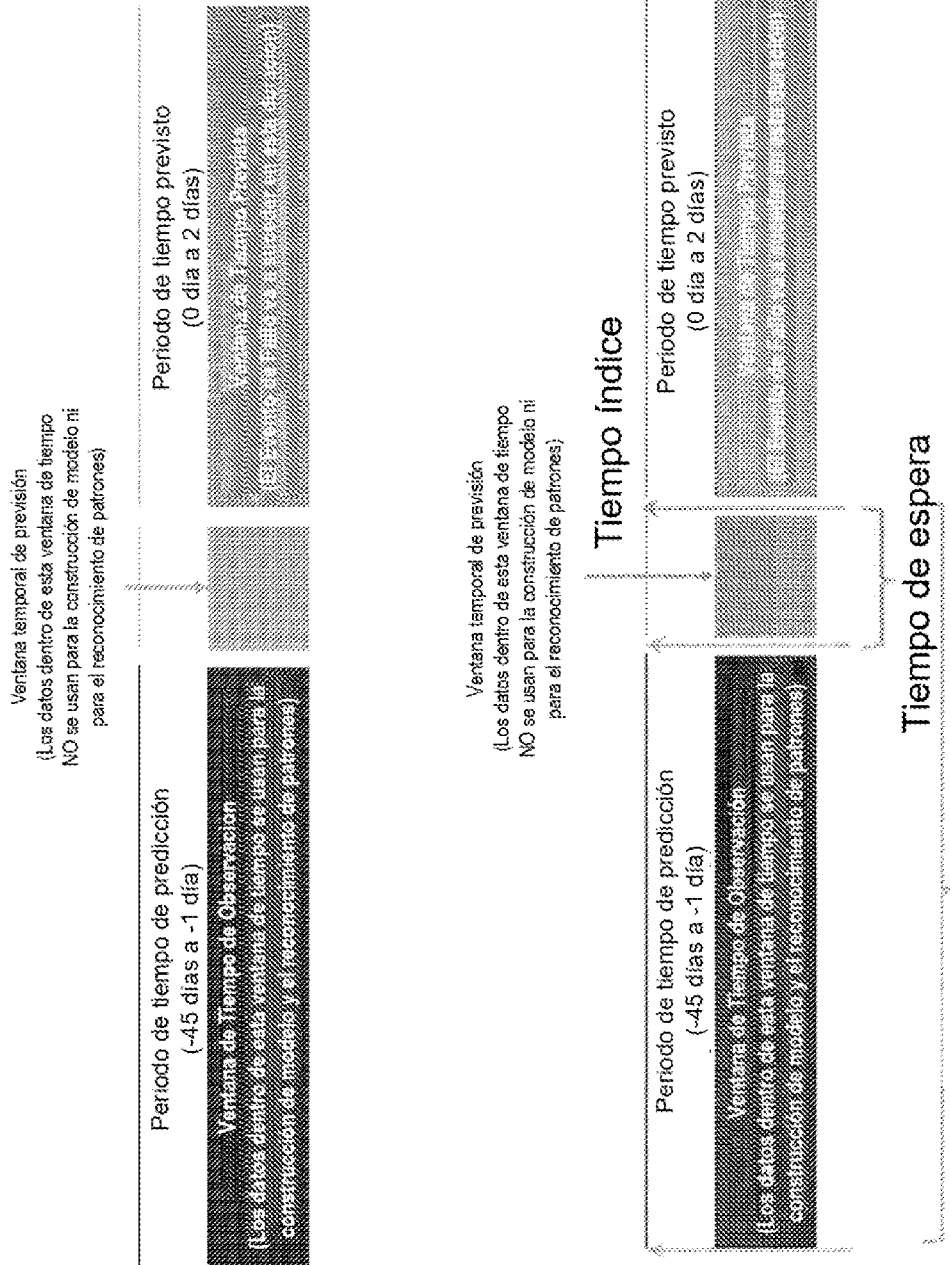


FIG. 5



Tiempo de retrospectiva **FIG. 6**





FIG. 7



\* El análisis de curvatura puede realizarse para todas las métricas de rendimiento

**FIG. 8**

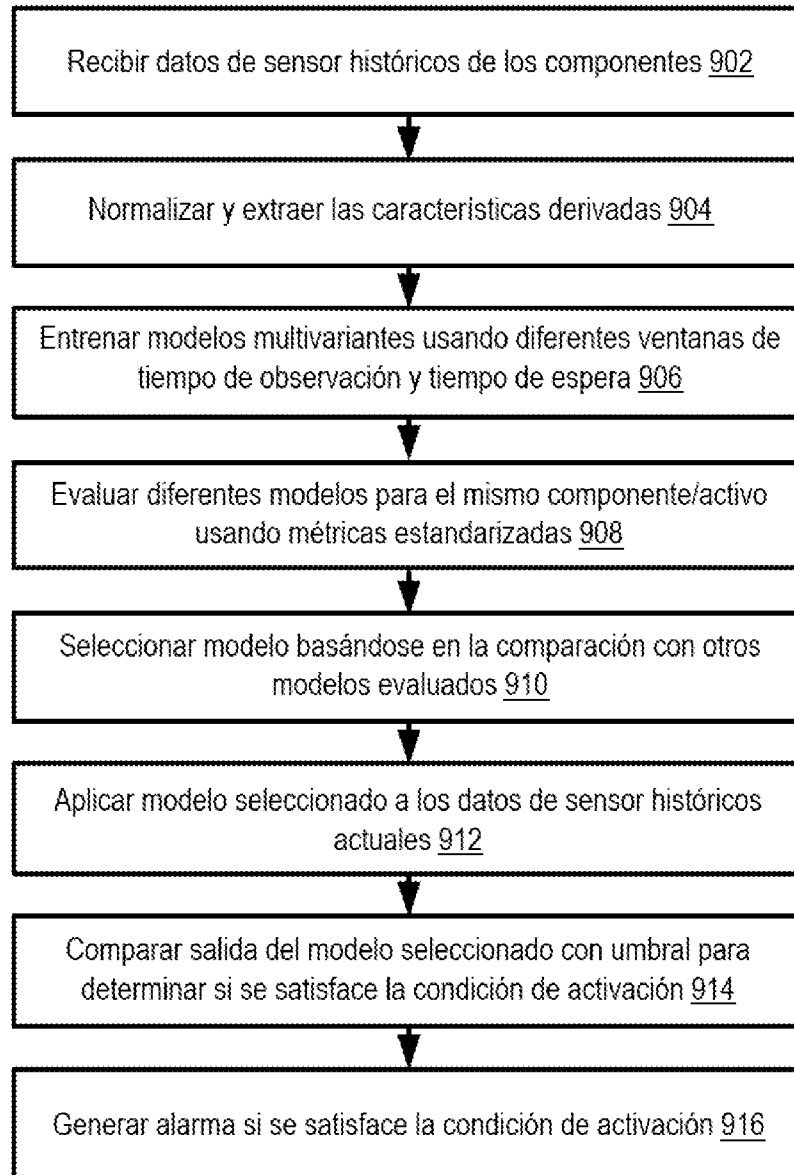


FIG. 9


$$\text{PMC} = \text{N.º de casos de fallo sin detectar} * \text{ARFC}$$
$$+ \text{N.º de casos de reparación preventiva} * \text{AFC}$$
$$+ \text{N.º de casos de visitas innecesarias} * \text{ACUV}$$

Tasa de Falsos Negativos \* Casos Totales

Tasa de Verdaderos Positivos \* Casos Totales

Tasa de Falsos Positivos \* Casos Totales

FIG. 10



Tiempo de Espera  
**FIG. 11**

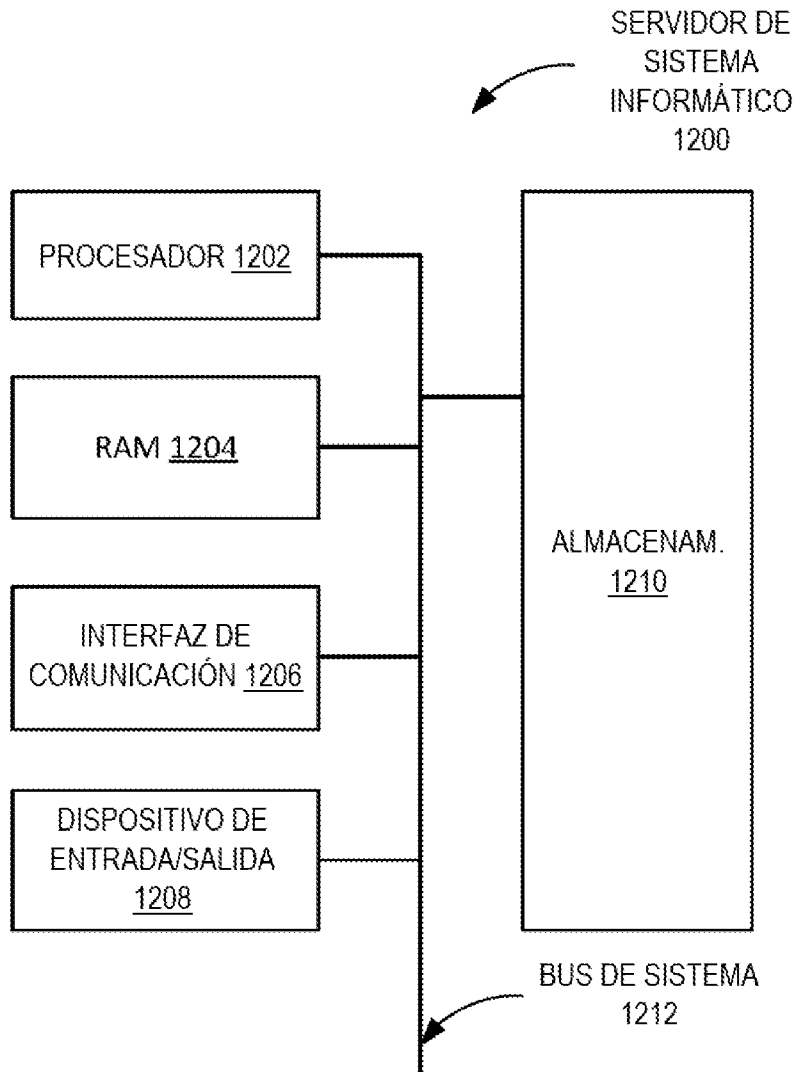


FIG. 12