

19



OFICINA ESPAÑOLA DE  
PATENTES Y MARCAS

ESPAÑA



11 Número de publicación: **2 995 869**

51 Int. Cl.:

**G06T 7/00** (2007.01)

**G06N 3/045** (2013.01)

12

TRADUCCIÓN DE PATENTE EUROPEA

T3

86 Fecha de presentación y número de la solicitud internacional: **30.06.2022 PCT/CN2022/102727**

87 Fecha y número de publicación internacional: **04.01.2024 WO24000372**

96 Fecha de presentación y número de la solicitud europea: **30.06.2022 E 22871101 (6)**

97 Fecha y número de publicación de la concesión europea: **11.09.2024 EP 4322106**

54 Título: **Método y aparato de detección de defectos**

45 Fecha de publicación y mención en BOPI de la traducción de la patente:  
**11.02.2025**

73 Titular/es:  
**CONTEMPORARY AMPEREX TECHNOLOGY  
(HONG KONG) LIMITED (100.00%)  
Level 19, China Building 29 Queen's Road Central  
Central, Central And Western District, HK**

72 Inventor/es:  
**JIANG, GUANNAN;  
SHU, ANNAN y  
HUANG, QIANGWEI**

74 Agente/Representante:  
**LEHMANN NOVO, María Isabel**

ES 2 995 869 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**

Método y aparato de detección de defectos

5 **CAMPO TÉCNICO**

Esta solicitud se refiere al campo técnico del procesamiento de imágenes y, en particular, a un método y aparato de detección de defectos,

10 **ANTECEDENTES**

En el campo de la fabricación industrial moderna, existen uno o más defectos en los productos industriales por razones de tecnología, dispositivos y producción multiproceso. Por lo tanto, llevar a cabo la detección de defectos en productos industriales es un eslabón clave para controlar la calidad de los productos industriales.

15 Debido a demasiadas capas de red, es difícil que el método común de detección de objetivos y el método de segmentación de instancias cumplan los requisitos de velocidad de detección en el proceso de producción de productos industriales. Por lo tanto, se necesita urgentemente un método eficaz de detección de defectos.

20 EL documento US 11.216.932 B1 proporciona un sistema, método y aparato para detectar defectos en un sustrato. Una imagen del sustrato se compara con una imagen de referencia para identificar posibles defectos. Las imágenes correspondientes a los posibles defectos son procesadas secuencialmente por un conjunto de clasificadores para generar un conjunto de imágenes que incluyen un defecto.

25 **SUMARIO**

Esta solicitud proporciona un método y un aparato de detección de defectos, para simplificar los procesos de detección de defectos y mejorar la eficiencia de detección.

30 Según un primer aspecto, se proporciona un método de detección de defectos, que incluye: obtener una imagen para su inspección; realizar la detección de anomalías en la imagen para su inspección para obtener una imagen de región de anomalía correspondiente a la imagen para su inspección; y realizar la clasificación de defectos en la imagen de región de anomalía para obtener información de detección de defectos de la imagen para su inspección.

35 En la solución técnica de esta aplicación, la detección de defectos se divide en dos etapas de detección de anomalías y clasificación de defectos. La primera se detecta una región anomalía en la imagen para su inspección para obtener la imagen de región de anomalía correspondiente a la imagen para su inspección. Después, la clasificación de defectos debe realizarse solo en la región de anomalía, reduciendo en gran medida la carga de trabajo de clasificación de defectos, mejorando así la eficiencia de la detección de defectos.

40 El método de detección de defectos de esta solicitud puede detectar y clasificar múltiples defectos, y es aplicable a múltiples procesos de producción, evitando así el desarrollo por separado de algoritmos de detección para cada proceso y reduciendo los costes de desarrollo.

45 En algunas realizaciones, la información de detección de defectos incluye información de tipo de defecto e información de ubicación de defectos de la imagen de región de anomalía.

50 Según la invención, la detección de anomalías realizada en la imagen para su inspección para obtener una imagen de región de anomalía correspondiente a la imagen para su inspección incluye: obtener, basándose en un modelo de detección de anomalías, una imagen de diferencia usada para representar una región de anomalía; y segmentar la imagen de diferencia basándose en un umbral de segmentación para obtener la imagen de región de anomalía.

55 En la realización anterior, el modelo de detección de anomalías se usa para inspeccionar la imagen para su inspección, con el fin de segmentar la región de anomalía de la imagen original para su inspección, de modo que la clasificación de defectos posterior se realice únicamente en la región de anomalía, reduciendo en gran medida la carga de trabajo de clasificación de defectos, mejorando así la eficacia de la detección de defectos.

60 Según la invención, el modelo de detección de anomalías incluye una red maestra preentrenada y una red estudiante destilada de la red maestra; y la obtención, basándose en un modelo de detección de anomalías, de una imagen de diferencia usada para representar una región de anomalía incluye: introducir la imagen para su inspección tanto en la red maestra como en la red estudiante para obtener imágenes de características de diferentes capas producidas por la red maestra e imágenes de características de diferentes capas producidas por la red estudiante; y calcular una diferencia entre cada píxel de las imágenes de características producidas por la red maestra y cada píxel de las imágenes de características producidas por la red estudiante para obtener la imagen de diferencia.

65

5 En la realización anterior, la región de anomalía se infiere de una diferencia entre la red maestra preentrenada y la red estudiante destilada de la red maestra en la expresión de una misma imagen para su inspección. De esta manera, se evita la comparación con muestras de imágenes defectuosas, evitando así la necesidad de recopilar y marcar manualmente una gran cantidad de datos de defectos por adelantado, y reduciendo los costes de mano de obra. Un grado de anomalía se define y cuantifica a través de la diferencia de expresión entre las imágenes de características producidas por las dos redes, y se implementa la detección de anomalías a nivel de píxeles de la imagen para su inspección.

10 En algunas realizaciones, la segmentación de la imagen de diferencia basándose en un umbral de segmentación para obtener la imagen de región de anomalía incluye: tomar los píxeles más altos que el umbral de segmentación en la imagen de diferencia como píxeles de anomalía y los píxeles restantes como píxeles normales, para obtener la imagen de región de anomalía.

15 En la realización anterior, la imagen de región de anomalía binarizada se obtiene segmentando la imagen de diferencia basándose en el umbral de segmentación, de modo que una región normal y una región de anomalía en la imagen para su inspección se pueden distinguir claramente entre sí y marcarse, y la clasificación de defectos se realiza solo en la región de anomalía pero no en la región normal en un proceso de clasificación de defectos posterior, reduciendo así en gran medida la carga de trabajo del proceso de clasificación de defectos y mejorando la eficiencia de la detección de defectos en su totalidad.

20 Debe entenderse que la región de anomalía es una región defectuosa. Cada píxel tiene sus propias coordenadas de posición. Por lo tanto, cuando la imagen de diferencia se segmenta basándose en el umbral de segmentación para obtener píxeles de anomalía, se pueden obtener coordenadas de posición de los píxeles de anomalía, de modo que se pueda obtener información de posición de la región de anomalía o de la región de defecto.

25 En algunas realizaciones, antes de realizar la detección de anomalías en la imagen para su inspección, el método incluye, además: entrenar la red estudiante del modelo de detección de anomalías.

30 Antes de que se realice la detección de anomalías en la imagen para su inspección, se entrena a la red estudiante en el modelo de detección de anomalías, lo que puede mejorar la precisión del modelo de detección de anomalías.

35 En algunas realizaciones, el entrenamiento de la red estudiante incluye: inicializar la red estudiante; introducir imágenes normales en la red maestra y la red estudiante para obtener imágenes de características de todas las capas producidas por la red maestra e imágenes de características correspondientes a todas las capas producidas por la red estudiante; minimizar las diferencias entre las imágenes de características de todas las capas producidas por la red maestra y las imágenes de características correspondientes a todas las capas producidas por la red estudiante en una función de pérdida por destilación; y actualizar los parámetros de la red estudiante basándose en los resultados del cálculo de pérdidas.

40 En la realización anterior, durante el entrenamiento de la red estudiante, la red estudiante adquiere una capacidad de extracción de características de la red maestra a través de la destilación del conocimiento, y obtiene, a través de la compresión del modelo, una capacidad de realizar detección de anomalías con pocos parámetros de red, y es de estructura simple. Por lo tanto, la red es fácil de desplegar e implementa una rápida detección de anomalías. Además, al aprender las imágenes normales en lugar de las imágenes defectuosas, la red de detección de anomalías puede detectar anomalías conocidas y desconocidas, y, por lo tanto, tiene una fuerte robustez porque evita la detección perdida de anomalías desconocidas.

50 Según la invención, el método incluye, además: calcular un umbral óptimo de determinación de anomalías del modelo de detección de anomalías; y establecer el umbral de segmentación basándose en el umbral óptimo de determinación de anomalías.

55 Se usa un umbral de determinación de anomalías para compararse con un valor máximo en una imagen de diferencia después de completar el entrenamiento de un modelo de detección de anomalías, a fin de determinar si una imagen para su inspección es una imagen normal o una imagen defectuosa. En la realización anterior, el umbral óptimo de determinación de anomalías se selecciona de modo que el modelo de detección de anomalías tenga una tasa de precisión más alta.

60 En algunas realizaciones, el cálculo de un umbral óptimo de determinación de anomalías del modelo de detección de anomalías incluye: introducir una muestra de prueba tanto en la red maestra como en la red estudiante, donde la muestra de prueba es una imagen defectuosa o una imagen normal; determinar un valor máximo en las imágenes de diferencias entre las imágenes de características producidas por la red maestra y las imágenes de características producidas por la red estudiante como un valor de anomalía de la muestra de prueba; bajo la condición de que el valor de anomalía sea superior al umbral de determinación de anomalías, determinar que la muestra de prueba es una imagen defectuosa, de lo contrario, determinar que la muestra de prueba es una imagen normal; y calcular una diferencia máxima entre una tasa de falsos positivos y una tasa de verdaderos positivos correspondiente a cada umbral de determinación de anomalías en el modelo de detección de anomalías, y determinar un umbral de determinación de

anomalías correspondiente a la diferencia máxima como umbral óptimo de determinación de anomalías; donde la tasa de falsos positivos es un porcentaje de muestras de prueba que se determinan incorrectamente como una imagen defectuosa, y la tasa de verdaderos positivos es un porcentaje de muestras de prueba que se determinan correctamente como una imagen defectuosa.

5 En la realización anterior, la diferencia entre la tasa de falsos positivos y la tasa de verdaderos positivos se usa para establecer el umbral óptimo de determinación de anomalías para el modelo de detección de anomalías, de modo que el modelo de detección de anomalías tenga una tasa de precisión más alta.

10 Según la invención, el ajuste del umbral de segmentación basándose en el umbral óptimo de determinación de anomalías incluye: establecer el umbral de segmentación para que sea menor que el umbral óptimo de determinación de anomalías.

15 En la realización anterior, el umbral de segmentación se establece para ser inferior al umbral óptimo de determinación de anomalías, de modo que marque posibles píxeles de anomalía como anormales, evitando de este modo la detección errónea, mejorando de este modo la tasa de precisión de la detección de anomalías.

20 En algunas realizaciones, antes de realizar la clasificación de defectos en la imagen de región de anomalía, el método incluye, además: obtener una o más imágenes rectangulares que incluyen píxeles de anomalía a partir de la imagen de región de anomalía; donde la realización de la clasificación de defectos en la imagen de región de anomalía incluye: realizar la clasificación de defectos en la una o más imágenes rectangulares.

25 En algunas realizaciones, la realización de la clasificación de defectos en la una o más imágenes rectangulares incluye: clasificar la imagen o imágenes rectangulares usando un modelo de clasificación de defectos.

En la realización anterior, la una o más imágenes rectangulares que incluyen píxeles de anomalía se obtienen a partir de la imagen de región de anomalía, lo que puede acelerar la inferencia por lotes posterior en la clasificación de defectos de la imagen de región de anomalía, mejorando de este modo la eficacia de la detección de defectos.

30 En algunas realizaciones, la clasificación de la imagen o imágenes rectangulares usando un modelo de clasificación de defectos incluye: obtener un vector de características de la imagen o imágenes rectangulares; calcular una puntuación de similitud de la imagen o imágenes rectangulares para cada tipo de defecto conocido basándose en el vector de características; y realizar la clasificación de defectos en la imagen o imágenes rectangulares basándose en la puntuación de similitud.

35 En la realización anterior, la clasificación de defectos se realiza en la imagen o imágenes rectangulares basándose en la puntuación de similitud, de modo que la similitud de un tipo de defecto de la imagen o imágenes rectangulares con cualquiera de los tipos de defectos conocidos se puede ver intuitivamente, para determinar con precisión la precisión de la clasificación de defectos.

40 En algunas realizaciones, la obtención de un vector de características de la imagen o imágenes rectangulares incluye: extraer el vector de características de la imagen o imágenes rectangulares usando un modelo de red ResNet.

45 En la realización anterior, el modelo de red ResNet es de estructura simple y, por lo tanto, ayuda a mejorar la eficacia de la clasificación de defectos, mejorando de este modo la eficacia de toda la detección de defectos.

50 En algunas realizaciones, el cálculo de una puntuación de similitud de la imagen o imágenes rectangulares para cada tipo de defecto conocido basándose en el vector de características incluye: asignar el vector de características a un espacio de vector de características entrenado, donde el espacio del vector de características incluye un vector de características para el tipo de defecto conocido; y calcular una distancia entre el vector de características y el vector de características para el tipo de defecto conocido, de modo que se obtenga la puntuación de similitud de la imagen o imágenes rectangulares para cada tipo de defecto conocido.

55 En la realización anterior, se puede visualizar un espacio de vector de características entrenado usando código relacionado, de modo que forme un espacio tridimensional, y el efecto del entrenamiento del modelo de clasificación de defectos para todos los tipos de defectos se puede ver intuitivamente observando el espacio de vector de características entrenado. Esto es bastante diferente del método convencional que presenta sólo información abstracta numérica.

60 En algunas realizaciones, la realización de la clasificación en la imagen o imágenes rectangulares basándose en la puntuación de similitud incluye: bajo la condición de que una puntuación máxima de similitud de las puntuaciones de similitud no sea inferior a un primer umbral de similitud, emitir un tipo de defecto correspondiente a la puntuación máxima de similitud; o bajo la condición de que las puntuaciones de similitud sean todas inferiores a un primer umbral de similitud, emitir un tipo de defecto desconocido.

65

- 5 En la realización anterior, el primer umbral de similitud se usa como un umbral de similitud más bajo. Bajo la condición de que las puntuaciones de similitud sean todas inferiores a esta puntuación, indica que un defecto de la imagen o imágenes rectangulares tiene una baja similitud con todos los defectos conocidos y, por lo tanto, es de un tipo de defecto desconocido. En esta realización de esta solicitud, un defecto desconocido o un nuevo defecto se puede identificar de manera precisa y eficaz.
- 10 En algunas realizaciones, antes de emitir un tipo de defecto correspondiente a la puntuación de similitud máxima, el método incluye además: bajo la condición de que el tipo de defecto sea un tipo de defecto especificado, calcular el área de los píxeles de anomalía en la imagen rectangular; donde la salida de un tipo de defecto correspondiente a la puntuación máxima de similitud incluye: bajo la condición de que el área sea mayor que un umbral de área, emitiendo el tipo de defecto correspondiente a la puntuación máxima de similitud.
- 15 En la realización anterior, un indicador de área de defecto específico se puede controlar de manera flexible según diferentes requisitos de tolerancia de área para un defecto.
- 20 En algunas realizaciones, la salida de un tipo de defecto correspondiente a la puntuación de similitud máxima incluye: bajo la condición de que la puntuación de similitud máxima sea mayor que un segundo umbral de similitud, emitir el tipo de defecto correspondiente a la puntuación de similitud máxima, donde el segundo umbral de similitud es mayor que el primer umbral de similitud.
- 25 En la realización anterior, el valor del segundo umbral de similitud se establece para que sea superior al primer umbral de similitud, de modo que el indicador del segundo umbral de similitud se pueda ajustar de manera flexible según diferentes requisitos de precisión de clasificación.
- 30 En algunas realizaciones, la información de detección de defectos incluye además una puntuación de similitud correspondiente a un tipo de defecto.
- 35 En la realización anterior, cuando la información de detección de defectos incluye una puntuación de similitud correspondiente a un tipo de defecto, puede observarse intuitivamente una similitud de un tipo de defecto de la imagen para su inspección con un tipo de defecto conocido, ayudando al personal a determinar, basándose en la puntuación de similitud, si es necesario realizar una determinación manual para comprobar si la detección de defectos es precisa.
- 40 Según un segundo aspecto, esta solicitud proporciona un aparato de detección de defectos que incluye: una unidad de obtención configurada para obtener una imagen para su inspección; y una unidad de procesamiento configurada para realizar la detección de anomalías en la imagen para su inspección para obtener una imagen de región de anomalía correspondiente a la imagen para su inspección; donde la unidad de procesamiento se configura además para realizar la clasificación de defectos en la imagen de región de anomalía para obtener información de detección de defectos de la imagen para su inspección.
- 45 En algunas realizaciones, la información de detección de defectos incluye información de tipo de defecto e información de ubicación de defectos de la imagen de región de anomalía.
- 50 En algunas realizaciones, la unidad de procesamiento se configura además para obtener, basándose en un modelo de detección de anomalías, una imagen de diferencia usada para representar una región de anomalía; y segmentar la imagen de diferencia basándose en un umbral de segmentación para obtener la imagen de región de anomalía.
- 55 En algunas realizaciones, el modelo de detección de anomalías incluye una red maestra preentrenada y una red estudiante destilada de la red maestra; la unidad de procesamiento se configura además para introducir la imagen para su inspección tanto en la red maestra como en la red estudiante para obtener imágenes de características producidas por la red maestra e imágenes de características producidas por la red estudiante; y la unidad de procesamiento se configura además para calcular una diferencia entre cada píxel de las imágenes de características producidas por la red maestra y cada píxel de las imágenes de características producidas por la red estudiante para obtener la imagen de diferencia.
- 60 En algunas realizaciones, la unidad de procesamiento se configura además para tomar los píxeles más altos que el umbral de segmentación en la imagen de diferencia como píxeles de anomalía y los píxeles restantes como píxeles normales, para obtener la imagen de región de anomalía.
- 65 En algunas realizaciones, la unidad de procesamiento se configura además para entrenar la red estudiante del modelo de detección de anomalías.
- En algunas realizaciones, la unidad de procesamiento se configura además para inicializar la red estudiante; la unidad de procesamiento se configura además para introducir imágenes normales en la red maestra y la red estudiante para obtener imágenes de características de todas las capas producidas por la red maestra e imágenes de características correspondientes a todas las capas producidas por la red estudiante; la unidad de procesamiento se configura además para minimizar las diferencias entre las imágenes de características de todas las capas producidas por la red maestra

y las imágenes de características correspondientes a todas las capas producidas por la red estudiante en una función de pérdida por destilación; y la unidad de procesamiento se configura además para actualizar los parámetros de la red estudiante basándose en los resultados del cálculo de pérdidas.

5 En algunas realizaciones, la unidad de procesamiento se configura además para calcular un umbral óptimo de determinación de anomalías del modelo óptimo de detección de anomalías del modelo de detección de anomalías; y la unidad de procesamiento se configura además para establecer el umbral de segmentación basándose en el umbral óptimo de determinación de anomalías.

10 En algunas realizaciones, la unidad de procesamiento se configura además para introducir una muestra de prueba tanto en la red maestra como en la red estudiante, donde la muestra de prueba es una imagen defectuosa o una imagen normal; la unidad de procesamiento se configura además para determinar un valor máximo en las imágenes de diferencias entre las imágenes de características producidas por la red maestra y las imágenes de características producidas por la red estudiante como un valor de anomalía de la muestra de prueba; bajo la condición de que el valor de anomalía sea superior al umbral de determinación de anomalías, la unidad de procesamiento se configura además para determinar que la muestra de prueba es una imagen defectuosa, de lo contrario, determinar que la muestra de prueba es una imagen normal; y la unidad de procesamiento se configura además para calcular una diferencia entre una tasa de falsos positivos y una tasa de verdaderos positivos correspondiente a cada umbral de determinación de anomalías en el modelo de detección de anomalías, y determinar un umbral de determinación de anomalías correspondiente a una diferencia máxima como umbral óptimo para determinar la anomalía; donde la tasa de falsos positivos es un porcentaje de muestras de prueba que se determinan incorrectamente como una imagen defectuosa, y la tasa de verdaderos positivos es un porcentaje de muestras de prueba que se determinan correctamente como una imagen defectuosa.

25 En algunas realizaciones, la unidad de procesamiento se configura además para establecer que el umbral de segmentación sea menor que el umbral óptimo de determinación de anomalías.

30 En algunas realizaciones, la unidad de obtención se configura además para obtener una o más imágenes rectangulares que incluyen píxeles de anomalía de la imagen de región de anomalía; y la unidad de procesamiento se configura además para realizar la clasificación de defectos en la una o más imágenes rectangulares.

En algunas realizaciones, la unidad de procesamiento se configura además para clasificar la imagen o imágenes rectangulares usando un modelo de clasificación de defectos.

35 En algunas realizaciones, la unidad de obtención se configura además para obtener un vector de características de la imagen o imágenes rectangulares; la unidad de procesamiento se configura además para calcular una puntuación de similitud de la imagen o imágenes rectangulares para cada tipo de defecto conocido basándose en el vector de características; y la unidad de procesamiento se configura además para realizar la clasificación de defectos en la imagen o imágenes rectangulares basándose en la puntuación de similitud.

40 En algunas realizaciones, la unidad de procesamiento se configura además para extraer el vector de características de la imagen o imágenes rectangulares usando un modelo de red ResNet.

45 En algunas realizaciones, la unidad de procesamiento se configura además para asignar el vector de características a un espacio de vector de características entrenado, donde el espacio de vector de características incluye un vector de características para el tipo de defecto conocido; y la unidad de procesamiento se configura además para calcular una distancia entre el vector de características y el vector de características para el tipo de defecto conocido, de modo que se obtenga la puntuación de similitud de la imagen o imágenes rectangulares para cada tipo de defecto conocido.

50 En algunas realizaciones, el aparato incluye además una unidad de salida 503; donde bajo la condición de que una puntuación de similitud máxima de las puntuaciones de similitud no sea inferior a un primer umbral de similitud, la unidad de salida está configurada para emitir un tipo de defecto correspondiente a la puntuación de similitud máxima; o bajo la condición de que las puntuaciones de similitud sean todas inferiores a un primer umbral de similitud, la unidad de salida 503 está configurada para emitir un tipo de defecto desconocido.

55 En algunas realizaciones, la unidad de procesamiento se configura además para: bajo la condición de que el tipo de defecto sea un tipo de defecto especificado, calcular el área de los píxeles de anomalía en la imagen rectangular; y la unidad de salida 503 incluye, además: bajo la condición de que el área sea mayor que un umbral de área, emitir el tipo de defecto correspondiente a la puntuación de similitud máxima.

60 En algunas realizaciones, la unidad de salida 503 se configura además para: bajo la condición de que la puntuación de similitud máxima sea mayor que un segundo umbral de similitud, emitir el tipo de defecto correspondiente a la puntuación de similitud máxima, donde el segundo umbral de similitud es mayor que el primer umbral de similitud.

65 En algunas realizaciones, la información de detección de defectos incluye además una puntuación de similitud correspondiente a un tipo de defecto.

El método de detección de defectos de las realizaciones de esta solicitud se divide en dos etapas de detección de anomalías y clasificación de defectos. La detección de anomalías se realiza primero en la imagen para su inspección, y después la clasificación de defectos debe realizarse solo en una región de anomalía, reduciendo la carga de trabajo de clasificación de defectos, mejorando así la eficiencia de la detección de defectos.

**BREVE DESCRIPCIÓN DE LOS DIBUJOS**

Para describir las soluciones técnicas en las realizaciones de esta solicitud con mayor claridad, a continuación, se describen brevemente los dibujos adjuntos necesarios para describir las realizaciones de esta solicitud. Como se apreciará, los dibujos adjuntos en la siguiente descripción muestran solo algunas realizaciones de esta solicitud, y una persona con conocimiento ordinario en la técnica aún puede derivar otros dibujos de los dibujos adjuntos sin realizar esfuerzos creativos.

- la Figura 1 es un diagrama esquemático una arquitectura del sistema según una realización de esta solicitud;
- la Figura 2 es un diagrama esquemático de un método de detección de defectos según una realización de esta solicitud;
- la Figura 3 es un diagrama estructural esquemático de un modelo detección de anomalías según una realización de esta solicitud;
- la Figura 4 es un diagrama esquemático un método para entrenar una red estudiante según una realización de esta solicitud;
- la Figura 5 es un diagrama estructural esquemático del entrenamiento de una red estudiante según una realización de esta solicitud;
- la Figura 6 es un diagrama de bloques esquemático de un aparato de detección de defectos según una realización de esta solicitud; y
- la Figura 7 es un diagrama estructural esquemático de un aparato de detección de defectos según una realización de esta solicitud.

Los dibujos adjuntos no están dibujados a escala.

**DESCRIPCIÓN DE LAS REALIZACIONES**

A continuación, se describen más en detalle las implementaciones de esta solicitud con referencia a los dibujos adjuntos y realizaciones. La descripción detallada de las realizaciones y los dibujos adjuntos pretenden ilustrar el principio de esta solicitud, en lugar de limitar el alcance de esta solicitud, lo que significa que esta solicitud no se limita a las realizaciones descritas en el presente documento.

En la descripción de esta solicitud, cabe destacar que, a menos que se indique lo contrario, "una pluralidad de" significa al menos dos; y las orientaciones o relaciones posicionales indicadas por los términos "superior", "inferior", "izquierda", "derecha", "interior", "exterior", y similares son solamente para facilitar y abreviar la descripción de esta solicitud en lugar de indicar o implicar que los aparatos o componentes mencionados deben tener orientaciones específicas o deben construirse o manipularse según orientaciones específicas. Por lo tanto, estos términos no se interpretarán como limitaciones a esta solicitud. Además, los términos "primero", "segundo", "tercero", y similares están destinados al propósito de descripción, y no se entenderán como cualquiera de una indicación o implicación de importancia relativa. "Perpendicular" no es perpendicular en sentido estricto, sino dentro de un rango de error admisible. "Paralelo" no es paralelo en sentido estricto, sino dentro de un rango de error admisible.

Los términos de orientación que aparecen en la siguiente descripción se refieren todos a las orientaciones como se muestran en los dibujos, y no limitan la estructura específica de esta solicitud. En las descripciones de esta solicitud, cabe señalar que, a menos que se especifique y defina explícitamente lo contrario, los términos "montaje", "interconexión" y "conexión" deben entenderse en un sentido amplio. Por ejemplo, puede ser una conexión fija, una conexión desmontable o una conexión integral; puede ser una conexión directa o una conexión indirecta a través de un medio intermedio. Una persona con un conocimiento ordinario de la técnica podrá entender los significados específicos de estos términos en esta solicitud basándose en las situaciones específicas.

la Figura 1 es un diagrama esquemático una batería secundaria según una realización de esta solicitud;  
 En la arquitectura del sistema mostrada en la Figura 1, una cámara 120 es un dispositivo que está conectado a una red actual y que puede usarse para fotografiar una batería de vehículo eléctrico. La cámara 120 puede transmitir una imagen para su inspección a través de la interacción de información con la red. Puede haber varias cámaras 120. Una imagen para su inspección capturada por la cámara 120 se puede transmitir directamente a un aparato de procesamiento 110, o se puede almacenar en una base de datos 140 primero y después acceder por el aparato de procesamiento 110 desde la base de datos 140. Se usa como ejemplo la obtención pasiva de una imagen para su inspección. Una nueva imagen para su inspección capturada por la cámara 120 puede ser capturada por el aparato de procesamiento 110 en tiempo real, o puede almacenarse primero en la base de datos 140, y después puede acceder por el aparato de procesamiento 110 desde la base de datos 140.

El aparato de procesamiento 110 está conectado comunicativamente a la cámara 120. Específicamente, el aparato de procesamiento 110 puede incluir una interfaz de comunicación 112 para establecer una conexión de comunicación con otros dispositivos. La conexión de comunicación puede ser cableada o inalámbrica.

5 El aparato de procesamiento 110 puede ser un dispositivo o sistema electrónico capaz de procesar datos, por ejemplo, un ordenador. El aparato de procesamiento 110 puede incluir un módulo de procesamiento 111 configurado para implementar la detección de defectos de la imagen para su inspección. El módulo de procesamiento 111 puede ser específicamente uno o más procesadores. El procesador puede ser cualquier tipo de procesador, que no está limitado en esta realización de esta solicitud.

10 El aparato de procesamiento 110 puede incluir además un sistema de almacenamiento 113. El sistema de almacenamiento 113 puede configurarse para almacenar datos e instrucciones, por ejemplo, instrucciones ejecutables por ordenador para implementar las soluciones técnicas de las realizaciones de esta solicitud. El aparato de procesamiento 110 puede llamar datos, instrucciones y similares en el sistema de almacenamiento 113, y también puede almacenar datos, instrucciones y similares en el sistema de almacenamiento 113. El sistema de almacenamiento 113 puede ser específicamente una o más memorias. La memoria puede ser cualquier tipo de memoria, que no está limitada en esta realización de esta solicitud.

15 El sistema de almacenamiento 113 se puede proporcionar dentro del aparato de procesamiento 110, o se puede proporcionar fuera del aparato de procesamiento 110. Si el sistema de almacenamiento 113 se proporciona fuera del aparato de procesamiento 110, el aparato de procesamiento 110 puede acceder al sistema de almacenamiento 113 a través de una interfaz de datos.

20 El aparato de procesamiento 110 puede incluir además otros dispositivos comunes, por ejemplo, un dispositivo de salida configurado para emitir un resultado de detección de defectos.

25 El aparato de procesamiento 110 incluye además un módulo de preprocesamiento 114 configurado para preprocesar la imagen para su inspección, por ejemplo, extraer un vector de características de la imagen para su inspección. Por ejemplo, el aparato de procesamiento 110 extrae un vector de características usando la siguiente solución técnica de las realizaciones de esta solicitud.

30 El aparato de procesamiento 110 se configura además con un modelo entrenado 115. En este caso, el módulo de procesamiento 111 puede usar el modelo 115 para realizar el procesamiento correspondiente. En esta solicitud, el modelo 115 se puede entrenar usando las soluciones técnicas de las realizaciones de esta solicitud.

35 Por ejemplo, el modelo 115 puede ser un modelo para la detección de defectos. Un dispositivo de entrenamiento 130 puede obtener un modelo de detección de defectos mediante el entrenamiento basándose en datos de entrenamiento en una base de datos de muestras 150. De esta manera, el módulo de procesamiento 111 puede usar el modelo de detección de defectos para obtener un tipo de defecto e información de ubicación de la imagen para su inspección.

40 Para obtener el vector de características de la imagen para su inspección, el vector de características puede extraerse primero mediante el módulo de preprocesamiento 114. Después, el vector de características se introduce en el modelo 115 para obtener el tipo de defecto y la información de ubicación de la imagen para su inspección.

45 Debe entenderse que la Figura 1 es solo un diagrama esquemático de una arquitectura del sistema según una realización de esta solicitud, y las relaciones de posición entre el dispositivo, componente, módulo y similares mostrados en la figura no constituyen ninguna limitación.

50 En algunas realizaciones posibles, el modelo 115 obtenido por el dispositivo de entrenamiento 130 mediante entrenamiento puede ser un modelo obtenido basándose en el aprendizaje automático, por ejemplo, un modelo construido basándose en una red neuronal. La red neuronal puede ser red neuronal convolucional (redes neuronales convolucionales, CNN), red neuronal recurrente (red neuronal recurrente, RNN), red neuronal convolucional profunda (redes neuronales convolucionales profundas, DCNN) o similares.

55 Actualmente, desde una perspectiva de desarrollo del mercado, las baterías de vehículos eléctricos se usan cada vez más. Las baterías de vehículos eléctricos no solo se usan en sistemas de suministro de energía primaria, como centrales eléctricas hidráulicas, eólicas, térmicas y solares, sino que también se usan ampliamente en herramientas de transporte eléctrico como bicicletas eléctricas, motocicletas eléctricas y vehículos eléctricos, y campos como equipos militares y aeroespaciales. Con la expansión continua de los campos de aplicación de las baterías de vehículos eléctricos, las demandas del mercado para las baterías de vehículos eléctricos también están aumentando. Durante la producción de baterías de vehículos eléctricos, pueden aparecer diferentes defectos en múltiples procesos, por ejemplo, troquelado de ánodo, troquelado de cátodo, bobinado, y huecograbado, y se debe aplicar tecnología visual para realizar la detección automática. Si se desarrolla un método de inspección visual para cada proceso, los costes son altos en su desarrollo y posterior implementación y mantenimiento. Actualmente, es necesario recopilar y marcar una gran cantidad de datos de defectos con antelación en todos los métodos comunes de detección de objetivos y métodos de segmentación de instancias. Esto no solo requiere recursos humanos, sino que también

conduce a muchos tipos de defectos en los productos reales. de forma adicional, una red de detección necesita hacer definiciones precisas de los tipos de defectos, pero a menudo es imposible definir con precisión todos los tipos de defectos en el mundo real, lo que da como resultado el riesgo de detección perdida de defectos. Además, es difícil que las redes de detección existentes cumplan con los requisitos de detección de alta velocidad en el proceso de producción de baterías de vehículos eléctricos porque las redes tienen muchas capas.

En vista de esto, una realización de esta solicitud proporciona un método de detección de defectos en el que la detección de defectos se divide en dos etapas de detección de anomalías y clasificación de defectos. Primero se determina una localización de defectos, y después la clasificación de defectos debe realizarse solo en una región de anomalía, reduciendo la carga de trabajo de clasificación de defectos, mejorando así la eficiencia de la detección de defectos.

El método y aparato de detección de defectos proporcionados en las realizaciones de esta solicitud se pueden usar para, pero sin limitación, detectar defectos de baterías de vehículos eléctricos, y también se pueden aplicar a la detección de defectos de otros tipos de productos en la fabricación industrial moderna. El proceso principal del método de detección de defectos en las realizaciones de esta solicitud se describe a continuación haciendo referencia a la Figura 2.

La Figura 2 es un gráfico de flujo esquemático de un método de detección de defectos 100 según una realización de esta solicitud. El método de detección de defectos 100 incluye las siguientes etapas.

101: Obtener una imagen para su inspección.

102: Realizar la detección de anomalías en la imagen para su inspección para obtener una imagen de región de anomalía correspondiente a la imagen para su inspección.

103: Realizar la clasificación de defectos en la imagen de región de anomalía para obtener información de detección de defectos de la imagen para su inspección.

Específicamente, en la etapa 101, la imagen para su inspección puede ser una imagen fotografiada por una cámara de dispositivo acoplado a carga (dispositivo acoplado a carga, CCD), o una imagen fotografiada por otras cámaras. Esto no está limitado en esta solicitud. La producción de baterías de vehículos eléctricos generalmente incluye múltiples procesos de producción. Cuando una batería del vehículo eléctrico llega al proceso final, la batería del vehículo eléctrico puede ser fotografiada por una cámara CCD para obtener la imagen para su inspección.

Específicamente, en la etapa 102, la región de anomalía puede marcarse en la imagen para su inspección para obtener la imagen de región de anomalía correspondiente a la imagen para su inspección. La imagen de región de anomalía incluye la región de anomalía, es decir, una región con un defecto, y también incluye una región normal, es decir, una región sin defecto.

En esta aplicación, la detección de defectos se divide en dos etapas de detección de anomalías y clasificación de defectos. La primera se detecta una región anomalía en la imagen para su inspección para obtener la imagen de región de anomalía correspondiente a la imagen para su inspección. Después, la clasificación de defectos debe realizarse solo en la región de anomalía, reduciendo en gran medida la carga de trabajo de clasificación de defectos, mejorando así la eficiencia de la detección de defectos.

El método de detección de defectos en esta realización de esta solicitud puede detectar y clasificar múltiples defectos, y es aplicable a múltiples procesos de producción, evitando así el desarrollo por separado de algoritmos de detección para cada proceso y reduciendo los costes de desarrollo.

Opcionalmente, en algunas realizaciones, la información de detección de defectos incluye información de tipo de defecto e información de ubicación de defectos de la imagen de región de anomalía.

Debe entenderse que cuando la imagen para su inspección incluye uno o más defectos, la información de detección de defectos puede incluir uno o más tipos de defectos e información de ubicación de defectos correspondiente.

Según la invención, la detección de anomalías realizada en la imagen para su inspección para obtener una imagen de región de anomalía correspondiente a la imagen para su inspección incluye: obtener, basándose en un modelo de detección de anomalías, una imagen de diferencia usada para representar una región de anomalía; y segmentar la imagen de diferencia basándose en un umbral de segmentación para obtener la imagen de región de anomalía.

Los píxeles son una unidad mínima en imágenes representadas por una secuencia digital. La imagen para la inspección está compuesta de múltiples píxeles, y cada píxel tiene sus propias coordenadas de ubicación y valor de color. La imagen de diferencia puede entenderse como una imagen que incluye coordenadas de ubicación de cada píxel de la imagen para su inspección y una puntuación de anomalía correspondiente del píxel, donde, basándose en el modelo de detección de anomalías, el píxel tiene una puntuación de anomalía, y cada puntuación de anomalía

puede representar la posibilidad de que se produzca anomalía en el píxel correspondiente. A continuación, se realiza la segmentación para cada píxel basándose en el umbral de segmentación y la imagen de diferencia, de modo que cada píxel se marca como un píxel normal o un píxel anomalía, para convertir la imagen para su inspección en una imagen de región anomalía que tiene una región normal y la región anomalía.

En la realización anterior, el modelo de detección de anomalías se usa para inspeccionar la imagen para su inspección, con el fin de segmentar la región de anomalía de la imagen original para su inspección, de modo que la clasificación de defectos posterior se realice únicamente en la región de anomalía, reduciendo en gran medida la carga de trabajo de clasificación de defectos, mejorando así la eficacia de la detección de defectos.

Según la invención, véase la Figura 2. La Figura 2 es un diagrama estructural esquemático de un modelo de detección de anomalías según una realización de esta solicitud. El modelo de detección de anomalías incluye una red maestra preentrenada y una red estudiante destilada de la red maestra. La obtención, basándose en un modelo de detección de anomalías, de una imagen de diferencia usada para representar una región de anomalía incluye: introducir la imagen para su inspección tanto en la red maestra como en la red estudiante para obtener una imagen de característica producida por la red maestra y una imagen de característica producida por la red estudiante; y calcular una diferencia entre cada píxel de las imágenes de características producidas por la red maestra y cada píxel del valor de características producido por la red estudiante para obtener la imagen de diferencia.

Como se muestra en la Figura 2, la red maestra preentrenada puede ser un modelo de red entrenado con antelación, y dicho modelo tiene potentes capacidades de extracción de características y análisis de imágenes. Por ejemplo, la red maestra preentrenada puede ser AlexNet, VGG, GoogleNet, ResNet, DenseNet, Senet, ShuteNet o MobileNet. La red estudiante es un modelo inicializado aleatoriamente que se destila de la red maestra preentrenada. El modelo maestro-estudiante se usa en la destilación del conocimiento, y una red compleja y grande se usa como red maestra, la red estudiante es simple en estructura y la red maestra se usa para ayudar a la formación de la red estudiante. Debido a su gran capacidad de aprendizaje, la red maestra puede transferir sus conocimientos aprendidos a la red estudiante con una capacidad de aprendizaje débil para mejorar la capacidad de generalización de la red estudiante. La red maestra transfiere la capacidad de extracción de características y clasificación de imágenes de imágenes normales a la red estudiante. La red estudiante no tiene conocimiento de la entrada de anomalías, mientras que la red maestra tiene conocimiento de la entrada de anomalías. Como resultado, en un caso de entrada de anomalía, las dos redes tienen una diferencia potencial en la expresión. Por lo tanto, la imagen de diferencia entre las imágenes de características producidas por las dos redes se puede usar para definir y cuantificar la anomalía, y después si un píxel es anormal y cuán anormal es el píxel se determina, basándose en un valor de anomalía del píxel en la imagen de diferencia, para implementar la detección de anomalías a nivel de píxeles en las imágenes.

Por lo tanto, la construcción de la red maestra-estudiante puede evitar la dificultad de recoger y marcar muestras de imágenes defectuosas en métodos tradicionales, ahorrando una gran cantidad de recursos humanos y materiales. Además, la formación de una red estudiante de alta calidad a través de la destilación del conocimiento transfiere la capacidad de extracción de características, y la definición de anomalías y la cuantificación del grado de anomalía se implementan a través de la diferencia de expresión entre las imágenes de características producidas por las dos redes, de modo que se implementa la detección de anomalías a nivel de píxeles de la imagen para su inspección.

Por ejemplo, tal como se muestra en la Figura 2, cuando la imagen para la inspección se introduce tanto en la red maestra como en la red estudiante, las imágenes de características de diferentes capas se pueden extraer de diferentes ubicaciones de las dos redes. Se usa una combinación de errores cuadrados medios de las imágenes de características que emiten las dos redes como imagen de diferencia, es decir, una imagen de distribución de valor de anomalía.

Opcionalmente, en algunas realizaciones, como se muestra en la Figura 2, la segmentación de la imagen de diferencia basándose en un umbral de segmentación para obtener la imagen de región de anomalía incluye: tomar los píxeles más altos que el umbral de segmentación en la imagen de diferencia como píxeles de anomalía y los píxeles restantes como píxeles normales, para obtener la imagen de región de anomalía.

El umbral de segmentación puede ser un valor preestablecido. La imagen de diferencia segmentada basándose en el umbral de segmentación significa realizar una dicotomía en una puntuación de anomalía de cada píxel de la imagen de diferencia basándose en el umbral de segmentación. Por ejemplo, un píxel con una puntuación de anomalía mayor que el umbral de segmentación se clasifica en una región de anomalía, y un píxel con una puntuación de anomalía inferior al umbral de segmentación se clasifica en una región normal. Múltiples píxeles adyacentes en la región de anomalía forman una región de anomalía, y puede haber una o más regiones de anomalía. Debe entenderse que un umbral de segmentación más grande significa que se clasifican menos píxeles en la región de anomalía, y que un umbral de segmentación más pequeño significa que se clasifican más píxeles en la región de anomalía. En otras palabras, el valor del umbral de segmentación determina el tamaño de la región de anomalía.

En la realización anterior, la imagen de región de anomalía binarizada se obtiene segmentando la imagen de diferencia basándose en el umbral de segmentación, de modo que una región normal y una región de anomalía en la imagen para su inspección se pueden distinguir claramente entre sí y marcarse, y la clasificación de defectos se realiza solo

en la región de anomalía pero no en la región normal en un proceso de clasificación de defectos posterior, reduciendo así en gran medida la carga de trabajo del proceso de clasificación de defectos y mejorando la eficiencia de la detección de defectos en su totalidad.

5 Debe entenderse que la región de anomalía es una región defectuosa. Cada píxel tiene sus propias coordenadas de posición. Por lo tanto, cuando la imagen de diferencia se segmenta basándose en el umbral de segmentación para obtener píxeles de anomalía, se pueden obtener coordenadas de posición de los píxeles de anomalía, de modo que se pueda obtener información de posición de la región de anomalía o de la región de defecto.

10 Opcionalmente, en algunas realizaciones, antes de realizar la detección de anomalías en la imagen para su inspección, el método de detección de defectos 100 incluye, además: entrenar la red estudiante del modelo de detección de anomalías.

15 Para mejorar la precisión del modelo de detección de anomalías, la red estudiante en el modelo de detección de anomalías puede entrenarse antes de que se realice la detección de anomalías en la imagen para su inspección.

Opcionalmente, en algunas realizaciones, véanse la Figura 3 y la Figura 4. La Figura 3 es un gráfico de flujo esquemático un método 200 para entrenar una red estudiante según una realización de esta solicitud. La Figura 4 es un diagrama estructural esquemático del entrenamiento de una red estudiante según una realización de esta solicitud. La imagen normal es una imagen sin defecto. El método 200 para entrenar una red estudiante incluye los siguientes pasos.

201: Inicializar la red estudiante.

25 202: Introducir imágenes normales en la red maestra y la red estudiante para obtener imágenes de características de todas las capas producidas por la red maestra e imágenes de características correspondientes a todas las capas producidas por la red estudiante.

30 203: Minimizar las diferencias entre las imágenes de características de todas las capas producidas por la red maestra y las imágenes de características correspondientes a todas las capas producidas por la red estudiante en una función de pérdida por destilación.

204: Actualizar los parámetros de la red estudiante basándose en los resultados de cálculo de pérdidas

35 Las etapas 202 a 204 se repiten para realizar una optimización iterativa continua hasta que se realice la convergencia.

40 Como se muestra en la Figura 4, cuando la red estudiante está entrenada, las imágenes normales se introducen en la red maestra y la red estudiante. Cuatro imágenes de características de diferentes capas se producen por las dos redes, y las cuatro imágenes de características tienen diferentes resoluciones. Una función de pérdida por destilación tal como la función de pérdida de L2 está diseñada para minimizar una distancia entre las dos redes en cada capa. La distancia mínima entre las dos redes puede ser, por ejemplo, un error cuadrado medio mínimo de las imágenes de características de diferentes capas de las dos redes.

45 Por lo tanto, durante el entrenamiento de la red estudiante, la red estudiante adquiere una capacidad de extracción de características de la red maestra a través de la destilación del conocimiento, y obtiene, a través de la compresión del modelo, una capacidad de realizar detección de anomalías con pocos parámetros de red, y es de estructura simple. Por lo tanto, la red es fácil de desplegar e implementa una rápida detección de anomalías. Además, al aprender las imágenes normales en lugar de las imágenes defectuosas, la red de detección de anomalías puede detectar anomalías conocidas y desconocidas, y, por lo tanto, tiene una fuerte robustez porque evita la detección perdida de anomalías desconocidas.

50 En esta realización de esta solicitud, la imagen normal puede ser una imagen sin defectos en diversos entornos de iluminación. Cuando se entrena a la red estudiante, también se pueden aplicar medios de mejora de imagen tales como la inestabilidad del brillo y la inestabilidad de saturación de las imágenes, de modo que el modelo de detección de anomalías tenga una fuerte robustez de la iluminación.

55 Según la invención, el método de detección de defectos 100 incluye, además: calcular un umbral óptimo de determinación de anomalías del modelo de detección de anomalías; y establecer el umbral de segmentación basándose en el umbral óptimo de determinación de anomalías.

60 Se usa un umbral de determinación de anomalías para compararse con un valor máximo en una imagen de diferencia después de completar el entrenamiento de un modelo de detección de anomalías, a fin de determinar si una imagen para su inspección es una imagen normal o una imagen defectuosa. El umbral óptimo de determinación de anomalías puede hacer que el modelo de detección de anomalías tenga una tasa de precisión más alta.

65

El umbral de segmentación debe establecerse en función del efecto de segmentación de la región de anomalía en la imagen de región de anomalía, para asegurar que todos los píxeles de anomalía estén segmentados, pero no se segmenten demasiados píxeles normales. En otras palabras, cuando la imagen de diferencia se segmenta en función del umbral de segmentación, se hacen los mejores esfuerzos para marcar los píxeles de anomalía reales como anormales y reducir los píxeles normales que se marcan como anormales, con el fin de mejorar la eficiencia de la clasificación posterior de defectos.

Opcionalmente, en algunas realizaciones, el umbral óptimo de determinación de anomalías del modelo de detección de anomalías se puede calcular de la siguiente manera: introducir una muestra de prueba tanto en la red maestra como en la red estudiante, donde la muestra de prueba es una imagen defectuosa o una imagen normal; determinar un valor máximo en las imágenes de diferencias entre las imágenes de características producidas por la red maestra y las imágenes de características producidas por la red estudiante como un valor de anomalía de la muestra de prueba; bajo la condición de que el valor de anomalía sea superior al umbral de determinación de anomalías, determinar que la muestra de prueba es una imagen defectuosa, de lo contrario, determinar que la muestra de prueba es una imagen normal; y calcular una diferencia máxima entre una tasa de falsos positivos y una tasa de verdaderos positivos correspondiente a cada umbral de determinación de anomalías en el modelo de detección de anomalías, y determinar un umbral de determinación de anomalías correspondiente a una diferencia máxima como el umbral óptimo de determinación de anomalías; donde la tasa de falsos positivos es un porcentaje de muestras de prueba que se determinan incorrectamente como una imagen defectuosa, y la tasa de verdaderos positivos es un porcentaje de muestras de prueba que se determinan correctamente como una imagen defectuosa.

La muestra de prueba es una imagen defectuosa o una imagen normal. Una imagen defectuosa puede incluir un tipo de defecto o múltiples tipos de defectos. Una imagen normal puede ser una imagen sin defecto. Alternativamente, una imagen normal puede ser una imagen defectuosa con un grado específico de tolerancia a fallos. En otras palabras, una imagen puede incluir un defecto, pero se permite un defecto de un pequeño rango específico en la detección de defectos, y, por lo tanto, la imagen puede considerarse una imagen normal.

Debe entenderse que después de completar el entrenamiento del modelo de detección de anomalías, es necesario establecer el umbral de determinación de anomalías y determinar, basándose en el umbral de determinación de anomalías y la imagen de diferencia, si la imagen para su inspección es una imagen defectuosa. Específicamente, diferentes umbrales de determinación de anomalías de las muestras de prueba significan diferentes tasas de exactitud inferentes del modelo de detección de anomalías.

Con el fin de que el modelo de detección de anomalías tenga una tasa de precisión más alta, la diferencia entre la tasa de falsos positivos y la tasa de verdaderos positivos se puede usar para establecer el umbral óptimo de determinación de anomalías.

Según la invención, el umbral de segmentación se establece para ser menor que el umbral de determinación de anomalías óptima.

El umbral de segmentación es generalmente inferior al umbral óptimo de determinación, de modo que marque posibles píxeles de anomalía como anormales, evitando de este modo la detección errónea, mejorando de este modo la tasa de precisión de la detección de anomalías.

Opcionalmente, en algunas realizaciones, antes de la etapa 103 de realizar la clasificación de defectos en la imagen de región de anomalía, el método 100 puede incluir, además: obtener una o más imágenes rectangulares que incluyen píxeles de anomalía a partir de la imagen de región de anomalía. En la etapa 103, la realización de la clasificación en la imagen de región de anomalía puede ser realizando la clasificación de defectos en la una o más imágenes rectangulares.

La obtención de una o más imágenes rectangulares que incluyen píxeles de anomalía de la imagen de región de anomalía puede entenderse como el corte de la imagen de región de anomalía usando un marco rectangular preestablecido, en concreto, cortando la región de anomalía de la imagen de región de anomalía en la imagen o imágenes rectangulares de un tamaño preestablecido. Específicamente, una región anomalía de un área grande se corta en múltiples imágenes rectangulares más pequeñas, y una región anomalía de un área pequeña se corta en una imagen rectangular.

La una o más imágenes rectangulares que incluyen píxeles de anomalía se obtienen a partir de la imagen de región de anomalía, lo que puede acelerar la inferencia por lotes posterior en la clasificación de defectos de la imagen de región de anomalía, mejorando de este modo la eficacia de la detección de defectos.

Ciertamente, en otras realizaciones de esta solicitud, una región de anomalía puede cortarse alternativamente en otras formas. Esto no está limitado en esta solicitud.

Opcionalmente, en algunas realizaciones, la realización de la clasificación de defectos en la una o más imágenes rectangulares incluye: clasificar la imagen o imágenes rectangulares usando un modelo de clasificación de defectos.

El modelo de clasificación de defectos puede realizar la clasificación de defectos en una imagen rectangular incluyendo píxeles de anomalía. Por ejemplo, el modelo de clasificación de defectos puede ser un modelo de red ResNet de baja complejidad. El modelo de red ResNet es un modelo de clasificación común. Para hacer inferencia o clasificación más rápida, se puede usar ResNet14 con una estructura de modelo más simple que ResNet18.

Para aumentar la precisión de la clasificación de defectos, se usa una función métrica de pérdida de aprendizaje para reemplazar una función softmax, para calcular una puntuación de similitud para cada tipo de defecto junto con el modelo ResNet14, para realizar la clasificación de defectos en la imagen o imágenes rectangulares.

Opcionalmente, en algunas realizaciones, cuando la imagen o imágenes rectangulares se clasifican usando el modelo de clasificación de defectos, se puede obtener primero un vector de características de la imagen o imágenes rectangulares; después se calcula una puntuación de similitud de la imagen o imágenes rectangulares para cada tipo de defecto conocido basándose en el vector de características; y después la clasificación de defectos se realiza en la imagen o imágenes rectangulares basándose en la puntuación de similitud.

Opcionalmente, en algunas realizaciones, el vector de características de la imagen o imágenes rectangulares se extrae usando un modelo de red ResNet.

Debe entenderse que el modelo de red ResNet puede extraer vectores de características. El modelo de red ResNet es de estructura simple y, por lo tanto, ayuda a mejorar la eficacia de la clasificación de defectos, mejorando de este modo la eficacia de toda la detección de defectos. Ciertamente, en otras realizaciones, también se pueden usar otros modelos para extraer vectores de características. Esto no está limitado en esta solicitud.

Opcionalmente, en algunas realizaciones, cuando la puntuación de similitud de la imagen o imágenes rectangulares para cada tipo de defecto conocido se calcula basándose en el vector de características: el vector de características se puede asignar primero a un espacio de vector de características entrenado, donde el espacio de vector de características incluye un vector de características para el tipo de defecto conocido; y después, se calcula una distancia entre el vector de características y el vector de características para el tipo de defecto conocido, de modo que se obtenga la puntuación de similitud de la imagen o imágenes rectangulares para cada tipo de defecto conocido.

El espacio del vector de características se puede entrenar usando una función métrica de pérdida de aprendizaje. Específicamente, se recoge un conjunto de muestras de imágenes defectuosas de un tipo de defecto conocido, y todas las imágenes defectuosas de un tipo de defecto conocido se introducen en un modelo de clasificación, tal como ResNet14. El modelo de clasificación extrae vectores de características de defectos de las imágenes defectuosas de un tipo de defecto conocido, y los vectores de características de defecto extraídos se colocan en un espacio de vector de características inicial. Después, la distribución de los vectores de características de defectos se optimiza en el espacio del vector de características usando la función métrica de pérdida de aprendizaje, es decir, se reduce una distancia de vectores de características de defecto de un mismo tipo, y una distancia de vectores de características de defecto de diferentes tipos o que tienen características bastante diferentes, para obtener un espacio de vector de características con una distribución de ubicación adecuada, es decir, un espacio de vector de características bien entrenado. Además, se puede visualizar un espacio de vector de características entrenado usando código relacionado, de modo que forme un espacio tridimensional, el efecto del entrenamiento del modelo de clasificación de defectos para todos los tipos de defectos se puede ver intuitivamente observando el espacio de vector de características entrenado. Esto es bastante diferente del método convencional que presenta sólo información abstracta numérica.

Después de extraer el vector de características de la imagen o imágenes rectangulares, el vector de características se asigna a un espacio de vector de características entrenado, y se calcula una distancia entre el vector de características y el vector de características para el tipo de defecto conocido en el espacio del vector de características, de modo que se obtenga la puntuación de similitud de la imagen o imágenes rectangulares para cada tipo de defecto conocido y se realice la clasificación de defectos en la imagen o imágenes rectangulares basándose en la puntuación de similitud.

La clasificación de defectos se realiza en la imagen o imágenes rectangulares basándose en la puntuación de similitud, de modo que la similitud de un tipo de defecto de la imagen o imágenes rectangulares con cualquiera de los tipos de defectos conocidos se puede ver intuitivamente, para determinar con precisión la precisión de la clasificación de defectos.

Opcionalmente, en algunas realizaciones, bajo la condición de que una puntuación máxima de similitud de las puntuaciones de similitud no sea inferior a un primer umbral de similitud, se emite un tipo de defecto correspondiente a la puntuación máxima de similitud; o bajo la condición de que las puntuaciones de similitud sean todas inferiores a un primer umbral de similitud, se emite un tipo de defecto desconocido.

El primer umbral de similitud se usa como un umbral de similitud más bajo. Bajo la condición de que las puntuaciones de similitud sean todas inferiores a esta puntuación, indica que un defecto de la imagen o imágenes rectangulares tiene una baja similitud con todos los defectos conocidos y, por lo tanto, es de un tipo de defecto desconocido o un

nuevo defecto. Cuando las puntuaciones de similitud son mayores que el primer umbral de similitud, se selecciona un tipo de defecto con una puntuación de similitud más alta como el tipo de defecto de la imagen o imágenes rectangulares.

5 Opcionalmente, en algunas realizaciones, antes de que se produzca el tipo de defecto correspondiente a la puntuación de similitud máxima, bajo la condición de que el tipo de defecto sea un tipo de defecto especificado, se calcula el área de los píxeles de anomalía en la imagen rectangular; o bajo la condición de que el área sea mayor que un umbral de área, se emite el tipo de defecto correspondiente a la puntuación de similitud máxima.

10 El umbral de área puede ser un valor preestablecido, y se pueden establecer diferentes umbrales de área para diferentes tipos de defectos y diferentes requisitos del cliente. Por ejemplo, para los defectos de troquelado de ánodo, una imagen rectangular se considera una imagen con un defecto de troquelado de ánodo solo cuando el área del defecto es mayor que el umbral de área, y se considera una imagen normal cuando el área es más pequeña que el umbral de área. En otras palabras, los productos industriales son tolerantes a defectos hasta cierto punto. Por lo tanto,  
15 en la realización anterior, un indicador de área de defecto específico se puede controlar de manera flexible según diferentes requisitos de tolerancia de área para un defecto.

Opcionalmente, en algunas realizaciones, bajo la condición de que la puntuación de similitud máxima sea mayor que un segundo umbral de similitud, se emite el tipo de defecto correspondiente a la puntuación de similitud máxima, donde  
20 el segundo umbral de similitud es mayor que el primer umbral de similitud.

En la realización opcional anterior, el segundo umbral de similitud puede ser un valor preestablecido, y diferentes clientes pueden establecer diferentes segundos umbrales de similitud basados en sus requisitos. Para los diferentes requisitos del cliente, puede haber diferentes criterios determinantes. Por ejemplo, para un cliente, una imagen rectangular se considera una imagen defectuosa de un tipo de defecto conocido solo cuando una puntuación máxima de similitud de la imagen rectangular para el tipo de defecto conocido es mayor que un umbral de similitud. En otras palabras, el cliente tiene un criterio determinante de similitud más alto para el propósito de una mayor precisión de clasificación. Por lo tanto, el indicador de exactitud de clasificación se puede ajustar de manera flexible con la  
25 realización anterior.

Opcionalmente, en algunas realizaciones, la información de detección de defectos incluye además una puntuación de similitud correspondiente a un tipo de defecto.  
30

Cuando la información de detección de defectos incluye una puntuación de similitud correspondiente a un tipo de defecto, puede observarse intuitivamente una similitud de un tipo de defecto de la imagen para su inspección con un tipo de defecto conocido, ayudando al personal a determinar, basándose en la puntuación de similitud, si es necesario realizar una determinación manual para comprobar si la detección de defectos es precisa.  
35

La realización del método de las realizaciones de esta solicitud se ha descrito en detalle anteriormente, y la realización del aparato de las realizaciones de esta solicitud se describe a continuación. La realización del aparato y la realización del método se corresponden entre sí y, por lo tanto, para el contenido no descrito en detalle, se puede hacer referencia a la realización del método anterior. El aparato puede implementar cualquier posible realización del método anterior.  
40

la Figura 6 es un diagrama de bloques esquemático de un aparato de detección de defectos 500 según una realización de esta solicitud. El aparato 500 realiza el método de detección de defectos de las realizaciones anteriores de esta solicitud. Por ejemplo, el aparato 500 es el aparato de procesamiento 110 anterior.  
45

Como se muestra en la Figura 6, el aparato incluye:

50 una unidad de obtención 501 configurada para obtener una imagen para su inspección; y  
una unidad de procesamiento 502 configurada para realizar la detección de anomalías en la imagen para su inspección para obtener una imagen de región de anomalía correspondiente a la imagen para su inspección; donde  
55 la unidad de procesamiento 503 se configura además para realizar la clasificación de defectos en la imagen de región de anomalía para obtener información de detección de defectos de la imagen para su inspección.

Según la invención, la unidad de procesamiento 502 se configura además para obtener, basándose en un modelo de detección de anomalías, una imagen de diferencia usada para representar una región de anomalía; y segmentar la imagen de diferencia basándose en un umbral de segmentación para obtener la imagen de región de anomalía.  
60

Según la invención, el modelo de detección de anomalías incluye una red maestra preentrenada y una red estudiante destilada de la red maestra; la unidad de procesamiento 502 se configura además para introducir la imagen para su inspección tanto en la red maestra como en la red estudiante para obtener imágenes de características producidas por la red maestra e imágenes de características producidas por la red estudiante; y calcular una diferencia entre cada pixel de las imágenes de características producidas por la red maestra y cada pixel de las imágenes de características producidas por la red estudiante para obtener la imagen de diferencia.  
65

Opcionalmente, en algunas realizaciones, la unidad de procesamiento 502 se configura además para tomar los píxeles más altos que el umbral de segmentación en la imagen de diferencia como píxeles de anomalía y los píxeles restantes como píxeles normales, para obtener la imagen de región de anomalía.

5 Según la invención, la unidad de procesamiento 502 se configura además para entrenar la red estudiante del modelo de detección de anomalías.

10 Opcionalmente, en algunas realizaciones, la unidad de procesamiento 502 se configura además para inicializar la red estudiante; introducir imágenes normales en la red maestra y la red estudiante para obtener imágenes de características de todas las capas producidas por la red maestra e imágenes de características correspondientes a todas las capas producidas por la red estudiante; minimizar las diferencias entre las imágenes de características de todas las capas producidas por la red maestra y las imágenes de características correspondientes a todas las capas producidas por la red estudiante en una función de pérdida por destilación; y actualizar los parámetros de la red estudiante basándose en los resultados del cálculo de pérdidas.

15 Según la invención, la unidad de procesamiento 502 se configura además para calcular un umbral óptimo de determinación de anomalías del modelo óptimo de detección de anomalías del modelo de detección de anomalías; y la unidad de procesamiento 502 se configura además para establecer el umbral de segmentación basándose en el umbral óptimo de determinación de anomalías.

20 Opcionalmente, en algunas realizaciones, la unidad de procesamiento 502 se configura además para introducir una muestra de prueba tanto en la red maestra como en la red estudiante, donde la muestra de prueba es una imagen defectuosa o una imagen normal; y determinar un valor máximo en las imágenes de diferencia entre las imágenes de características producidas por la red maestra y las imágenes de características producidas por la red estudiante como un valor de anomalía de la muestra de prueba. Si el valor de anomalía es mayor que el umbral de determinación de anomalías, la unidad de procesamiento 502 se configura además para determinar que la muestra de prueba es una imagen defectuosa, de lo contrario, determinar que la muestra de prueba es una imagen normal. La unidad de procesamiento 502 se configura además para calcular una diferencia entre una tasa de falsos positivos y una tasa de verdaderos positivos correspondiente a cada umbral de determinación de anomalías en el modelo de detección de anomalías, y determinar un umbral de determinación de anomalías correspondiente a una diferencia máxima como el umbral óptimo de determinación de anomalías. La tasa de falsos positivos es un porcentaje de muestras de prueba que se determinan incorrectamente como una imagen defectuosa, y la tasa de verdaderos positivos es un porcentaje de muestras de prueba que se determinan correctamente como una imagen defectuosa.

25 Según la invención, la unidad de procesamiento 502 se configura además para establecer que el umbral de segmentación sea menor que el umbral óptimo de determinación de anomalías.

30 Opcionalmente, en algunas realizaciones, la unidad de obtención 501 se configura además para obtener una o más imágenes rectangulares que incluyen píxeles de anomalía de la imagen de región de anomalía; y realizar la clasificación de defectos en la una o más imágenes rectangulares.

35 Opcionalmente, en algunas realizaciones, la unidad de procesamiento 502 se configura además para clasificar la imagen o imágenes rectangulares usando un modelo de clasificación de defectos.

40 Opcionalmente, en algunas realizaciones, la unidad de obtención 501 se configura además para obtener un vector de características de la imagen o imágenes rectangulares; calcular una puntuación de similitud de la imagen o imágenes rectangulares en términos de cada tipo de defecto conocido basándose en el vector de características; y realizar la clasificación de defectos en la imagen o imágenes rectangulares basándose en la puntuación de similitud.

45 Opcionalmente, en algunas realizaciones, la unidad de procesamiento 502 se configura además para extraer el vector de características de la imagen o imágenes rectangulares usando un modelo de red ResNet.

50 Opcionalmente, en algunas realizaciones, la unidad de procesamiento 502 se configura además para asignar el vector de características a un espacio de vector de características entrenado, donde el espacio de vector de características incluye un vector de características para el tipo de defecto conocido; y calcular una distancia entre el vector de características y el vector de características para el tipo de defecto conocido, de modo que se obtenga la puntuación de similitud de la imagen o imágenes rectangulares para cada tipo de defecto conocido.

55 Opcionalmente, en algunas realizaciones, el aparato incluye además una unidad de salida 503; donde bajo la condición de que una puntuación de similitud máxima de las puntuaciones de similitud no sea inferior a un primer umbral de similitud, la unidad de salida 503 está configurada para emitir un tipo de defecto correspondiente a la puntuación de similitud máxima; o bajo la condición de que las puntuaciones de similitud sean todas inferiores a un primer umbral de similitud, la unidad de salida 503 está configurada para emitir un tipo de defecto desconocido.

60

65

Opcionalmente, en algunas realizaciones, la unidad de procesamiento 502 se configura además para: bajo la condición de que el tipo de defecto sea un tipo de defecto especificado, calcular el área de los píxeles de anomalía en la imagen rectangular; y la unidad de salida 503 incluye, además: bajo la condición de que el área sea mayor que un umbral de área, emitir el tipo de defecto correspondiente a la puntuación de similitud máxima.

Opcionalmente, en algunas realizaciones, la unidad de salida 503 se configura además para: bajo la condición de que la puntuación de similitud máxima sea mayor que un segundo umbral de similitud, emitir el tipo de defecto correspondiente a la puntuación de similitud máxima, donde el segundo umbral de similitud es mayor que el primer umbral de similitud.

La Figura 7 es un diagrama estructural esquemático del hardware de un aparato de detección de defectos según una realización de esta solicitud. El aparato de detección de defectos 600 mostrado en la Figura 7 incluye una memoria 601, un procesador 602, una interfaz de comunicación 603 y un bus 604. La memoria 601, el procesador 602 y la interfaz de comunicación 603 están conectados entre sí a través del bus 604.

La memoria 601 puede ser una memoria de solo lectura (memoria de solo lectura, ROM), un dispositivo de almacenamiento estático o una memoria de acceso aleatorio (memoria de acceso aleatorio, RAM). La memoria 601 puede almacenar un programa. Cuando el programa almacenado en la memoria 601 es ejecutado por el procesador 602, el procesador 602 y la interfaz de comunicación 603 están configurados para realizar los pasos del método de detección de defectos de las realizaciones de esta solicitud.

El procesador 602 puede ser una unidad central de procesamiento de propósito general (central processing unit, CPU), un microprocesador, un circuito integrado específico de aplicación (application specific integrated circuit, ASIC), una unidad de procesamiento de gráficos (graphics processing unit, GPU) o uno o más circuitos integrados, y está configurado para ejecutar un programa relacionado de modo que implemente las funciones requeridas por las unidades en el aparato de detección de defectos de esta realización de esta solicitud, o realizar el método de detección de defectos de las realizaciones de esta solicitud.

El procesador 602 puede alternativamente ser un chip de circuito integrado con una capacidad de procesamiento de señales. Durante la implementación, las etapas del método de detección de defectos en las realizaciones de esta solicitud pueden implementarse mediante circuitos lógicos integrados por hardware en el procesador 602 o instrucciones en forma de software.

El procesador 602 puede ser alternativamente un procesador de propósito general, un procesador de señales digitales (digital signal processor, DSP), un ASIC, una matriz de puertas programable en campo (field programmable gate array, FPGA) u otro dispositivo lógico programable, un dispositivo lógico de puerta o transistor discreto, o un componente de hardware discreto. El procesador 602 puede implementar o realizar los métodos, etapas y diagramas de bloques de lógica divulgados en las realizaciones de la presente solicitud. El procesador de uso general puede ser un microprocesador, o el procesador puede ser también cualquier procesador convencional o similar. Las etapas de los métodos divulgados con referencia a las realizaciones de esta solicitud pueden realizarse y completarse directamente usando un procesador de hardware, o pueden realizarse y completarse usando una combinación de hardware en el procesador y un módulo de software. El módulo de software puede estar ubicado en un medio de almacenamiento maduro en la técnica, tal como una memoria de acceso aleatorio, una memoria flash, una memoria de solo lectura, una memoria programable de solo lectura o una memoria programable borrrable eléctricamente, o un registro. El medio de almacenamiento está ubicado en la memoria 601. El procesador 602 obtiene información en la memoria 601 y completa, junto con el hardware del procesador 602, las funciones requeridas por las unidades en el aparato de detección de defectos de esta realización de esta solicitud, o realiza el método de detección de defectos de las realizaciones de esta solicitud.

La interfaz de comunicación 603 implementa la comunicación entre el aparato 600 y otros dispositivos o redes de comunicación usando un aparato transceptor tal como, pero sin limitación, un transceptor. Por ejemplo, los datos de tráfico de un dispositivo desconocido se pueden obtener a través de la interfaz de comunicación 603.

El bus 604 puede incluir una trayectoria para transferir información entre diversos componentes del aparato 600 (por ejemplo, la memoria 601, el procesador 602 y la interfaz de comunicación 603).

Cabe destacar que, aunque solo se muestran la memoria, el procesador y la interfaz de comunicación del aparato 600, en una implementación específica, los expertos en la materia deben entender que el aparato 600 puede incluir además otros componentes necesarios para su funcionamiento normal. Además, los expertos en la materia deben entender que, basándose en necesidades específicas, el aparato 600 puede incluir además un componente de hardware para implementar otras funciones adicionales. Además, los expertos en la técnica deben entender que el aparato 600 puede incluir solo componentes necesarios para implementar las realizaciones de esta solicitud, y no necesariamente incluye todos los componentes mostrados en la Figura 7.

Una realización de esta solicitud proporciona además un medio de almacenamiento legible por ordenador. El medio almacena el código de programa para ser ejecutado por un dispositivo. El código de programa incluye instrucciones para realizar las etapas del método de detección de defectos anterior.

5 Una realización de esta solicitud proporciona además un producto de programa informático. El producto de programa informático incluye un programa informático almacenado en un medio de almacenamiento legible por ordenador, y el programa informático incluye instrucciones del programa. Cuando las instrucciones del programa son ejecutadas por un ordenador, el ordenador está habilitado para realizar el método de detección de defectos anterior.

10 El medio de almacenamiento legible por ordenador puede ser un medio de almacenamiento transitorio legible por ordenador o un medio de almacenamiento legible por ordenador no transitorio.

Un experto en la técnica puede entender claramente que, con el fin de una descripción conveniente y breve, para un proceso de trabajo detallado del aparato anterior, se puede hacer referencia a un proceso correspondiente en las realizaciones del método anteriores, y los detalles no se describen de nuevo en el presente documento.

15 En las varias realizaciones proporcionadas en esta solicitud, debe entenderse que el aparato y método descritos pueden implementarse de otras formas. Por ejemplo, la realización del aparato descrita es meramente un ejemplo. Por ejemplo, la división de unidades es simplemente una división lógica de funciones y puede ser otra división en la implementación real. Por ejemplo, una pluralidad de unidades o componentes pueden combinarse o integrarse en otro sistema, o algunas características pueden ignorarse o pueden no realizarse. Además, los acoplamientos mutuos mostrados o analizados o acoplamientos directos o conexiones de comunicación pueden implementarse a través de algunas interfaces. Los acoplamientos indirectos o las conexiones de comunicación entre los aparatos o unidades pueden implementarse en formas eléctricas, mecánicas u otras.

20 Los términos usados en esta solicitud se usan simplemente para describir las realizaciones y no para limitar las reivindicaciones. Como se usa en la descripción de las realizaciones y las reivindicaciones, a menos que se indique claramente lo contrario en el contexto, las formas singulares "un/una" y "el/la" incluyen también las formas plurales. De manera similar, el término "y/o", tal como se usa en esta solicitud, pretende incluir todas y cada una de las combinaciones posibles de uno o más de los artículos enumerados asociados. Además, cuando se usa en esta solicitud, el término "incluir" especifica que las características, números enteros, etapas, operaciones, elementos indicados, y/o componentes existen, pero no excluye que una o más características, números enteros, etapas, operaciones, elementos, existen o se añaden componentes y/o agrupaciones de los mismos.

25 Los aspectos de las realizaciones descritas pueden implementarse mediante software, hardware o una combinación de software y hardware. Como alternativa, las realizaciones descritas se pueden realizar mediante un medio legible por ordenador que almacena código legible por ordenador. El código legible por ordenador incluye instrucciones ejecutables por al menos un aparato informático. El medio legible por ordenador puede estar asociado con cualquier aparato de almacenamiento de datos que pueda almacenar datos. Los datos pueden ser accedidos por un sistema informático. Un medio legible por ordenador de ejemplo puede incluir memoria de solo lectura, memoria de acceso aleatorio, memoria de solo lectura de disco compacta (Compact Disc Read-Only Memory, CD-ROM), unidad de disco duro (Hard Disk Drive, HDD), disco de vídeo digital (Digital Video Disc, DVD), cinta magnética, aparato de almacenamiento de datos ópticos o similares. El medio legible por ordenador se puede distribuir alternativamente a través de un sistema informático conectado a través de una red de modo que el código legible por ordenador se pueda almacenar y ejecutar de forma distribuida.

30 La descripción técnica anterior puede referirse a los dibujos adjuntos que forman parte de esta solicitud y presenta la implementación según las realizaciones descritas en los dibujos adjuntos. Aunque estas realizaciones se describen con suficiente detalle para permitir a los expertos en la materia implementar las realizaciones, estas realizaciones no son limitativas de modo que se puedan usar otras realizaciones. Además, se pueden realizar modificaciones adicionalmente sin alejarse del alcance de las realizaciones descritas, siempre que estas modificaciones estén cubiertas por las reivindicaciones. Por ejemplo, el orden de operación descrito en los diagramas de flujo no es limitativo y, por lo tanto, el orden de dos o más operaciones ilustradas y descritas según el diagrama de flujo puede cambiarse basándose en varias realizaciones. Por otro ejemplo, en varias realizaciones, una o más operaciones ilustradas y descritas según el diagrama de flujo son opcionales, o pueden eliminarse. Además, se pueden añadir algunas etapas o funcionalidades a las realizaciones divulgadas, o se pueden permutar dos o más etapas. Se considera que todas estas variaciones están englobadas por las realizaciones divulgadas y las reivindicaciones.

35 Además, se usan términos en la descripción técnica anterior para proporcionar una comprensión exhaustiva de las realizaciones descritas. Sin embargo, no se requieren detalles indebidos para implementar las realizaciones descritas. Por lo tanto, la descripción anterior de las realizaciones se presenta con fines de ilustración y descripción. Las realizaciones presentadas en la descripción anterior y los ejemplos divulgados según estas realizaciones se proporcionan para ofrecer contexto y facilitar la comprensión de las realizaciones descritas. La descripción anterior no pretende ser exhaustiva ni limitar esta solicitud a las realizaciones descritas en una forma precisa. Varias modificaciones, alternativas y variaciones son posibles según las enseñanzas anteriores. En algunos casos, no se han descrito en detalle etapas del proceso bien conocidas para no oscurecer innecesariamente las realizaciones descritas.

Aunque esta solicitud se ha descrito con referencia a las realizaciones preferidas, se pueden realizar diversas modificaciones a esta solicitud sin alejarse del alcance de esta solicitud y los componentes en la misma se pueden reemplazar con equivalentes, siempre que estas modificaciones y reemplazos estén cubiertos por las reivindicaciones. Esta solicitud no se limita a las realizaciones específicas divulgadas en esta memoria descriptiva, sino que incluye todas las soluciones técnicas que entran dentro del alcance de las reivindicaciones.

5

REIVINDICACIONES

1. Un método de detección de defectos (100) para su ejecución por parte de un aparato de detección de defectos (500), comprendiendo el método:
- 5 obtener (101) una imagen para su inspección.  
 realizar la detección de anomalías (102) en la imagen para su inspección para obtener una imagen de región de anomalía correspondiente a la imagen para su inspección; y  
 realizar la clasificación de defectos (103) en la imagen de región de anomalía para obtener información de detección de defectos de la imagen para su inspección, la realización de la detección de anomalías (102) en la imagen para su inspección para obtener una imagen de región de anomalía correspondiente a la imagen para su inspección comprende:
- 10 obtener, basándose en un modelo de detección de anomalías, una imagen de diferencia usada para representar una región de anomalía; y  
 segmentar la imagen de diferencia basándose en un umbral de segmentación para obtener la imagen de región de anomalía,
- 15 **caracterizado por que**  
 el modelo de detección de anomalías comprende una red maestra preentrenada y una red estudiante destilada de la red maestra; y  
 la obtención, basándose en un modelo de detección de anomalías, de una imagen de diferencia usada para representar una región de anomalía comprende: introducir la imagen para su inspección tanto en la red maestra como en la red estudiante para obtener imágenes de características producidas por la red maestra e imágenes de características producidas por la red estudiante; y  
 calcular una diferencia entre cada píxel de las imágenes de características producidas por la red maestra y cada píxel de las imágenes de características producidas por la red estudiante para obtener la imagen de diferencia;
- 20 en donde, el método comprende, además: calcular un umbral óptimo de determinación de anomalías del modelo de detección de anomalías; y establecer el umbral de segmentación para ser menor que el umbral óptimo de determinación de anomalías.
2. El método de detección de defectos (100) según la reivindicación 1, **caracterizado por que** la información de detección de defectos comprende información de tipo de defecto e información de ubicación de defectos de la imagen de región de anomalía.
3. El método de detección de defectos (100) según la reivindicación 1 o 2, **caracterizado por que** la segmentación de la imagen de diferencia basándose en un umbral de segmentación para obtener la imagen de región de anomalía comprende:
- 35 tomar píxeles con una puntuación de anomalía mayor que el umbral de segmentación en la imagen de diferencia como píxeles de anomalía y los píxeles restantes como píxeles normales, para obtener la imagen de región de anomalía.
4. El método de detección de defectos (100) según una cualquiera de las reivindicaciones anteriores, **caracterizado por que** antes de realizar la detección de anomalías (102) en la imagen para su inspección, el método comprende, además:
- 40 entrenar la red estudiante del modelo de detección de anomalías; opcionalmente, el entrenamiento de la red estudiante comprende:  
 inicializar (201) la red estudiante.  
 introducir (202) imágenes normales en la red maestra y la red estudiante para obtener imágenes de características de todas las capas producidas por la red maestra e imágenes de características correspondientes a todas las capas producidas por la red estudiante.  
 minimizar (203) las diferencias entre las imágenes de características de todas las capas producidas por la red maestra y las imágenes de características correspondientes a todas las capas producidas por la red estudiante en una función de pérdida por destilación; y  
 actualizar (204) los parámetros de la red estudiante basándose en los resultados de cálculo de pérdidas
- 45
5. El método de detección de defectos (100) según cualquiera de las reivindicaciones anteriores, **caracterizado por que** el cálculo de un umbral óptimo de determinación de anomalías del modelo de detección de anomalías comprende:
- 55 introducir una muestra de prueba tanto en la red maestra como en la red estudiante, donde la muestra de prueba es una imagen defectuosa o una imagen normal;  
 determinar un valor máximo en las imágenes de diferencia entre las imágenes de características producidas por la red maestra y las imágenes de características producidas por la red estudiante como valor de anomalía de la muestra de prueba;
- 60 bajo la condición de que el valor de anomalía es superior al umbral de determinación de anomalías, determinar que la muestra de prueba es una imagen defectuosa, de lo contrario, determinar que la muestra de prueba es una imagen normal, y  
 calcular una diferencia entre una tasa de falsos positivos y una tasa de verdaderos positivos correspondiente a cada umbral de determinación de anomalías en el modelo de detección de anomalías, y determinar un umbral de determinación de anomalías correspondiente a una diferencia máxima como el umbral óptimo de determinación de anomalías; en donde
- 65

la tasa de falsos positivos es un porcentaje de muestras de prueba que se determinan incorrectamente como una imagen defectuosa, y la tasa de verdaderos positivos es un porcentaje de muestras de prueba que se determinan correctamente como una imagen defectuosa.

- 5 6. El método de detección de defectos (100) según una cualquiera de las reivindicaciones 1 a 5, **caracterizado por que** antes de realizar la clasificación de defectos (103) en la imagen de región de anomalía, el método comprende, además:  
 obtener una o más imágenes rectangulares que comprenden píxeles de anomalía a partir de la imagen de región de anomalía; en donde
- 10 la realización de la clasificación de defectos (103) en la imagen de región de anomalía comprende:  
 realizar la clasificación de defectos en la una o más imágenes rectangulares; opcionalmente, la realización de la clasificación de defectos en la una o más imágenes rectangulares comprende:  
 clasificar la imagen o imágenes rectangulares usando un modelo de clasificación de defectos; opcionalmente, la clasificación de la imagen o imágenes rectangulares usando un modelo de clasificación de defectos comprende:
- 15 obtener un vector de características de la imagen o imágenes rectangulares;  
 calcular una puntuación de similitud de la imagen o imágenes rectangulares para cada tipo de defecto conocido basándose en el vector de características; y  
 realizar la clasificación de defectos en la imagen o imágenes rectangulares basándose en la puntuación de similitud; y opcionalmente, la obtención de un vector de características de la imagen o imágenes rectangulares comprende:
- 20 extraer el vector de características de la imagen o imágenes rectangulares usando un modelo de red ResNet.
7. El método de detección de defectos (100) según la reivindicación 6, **caracterizado por que** el cálculo de una puntuación de similitud de la imagen o imágenes rectangulares para cada tipo de defecto conocido basándose en el vector de características comprende:
- 25 asignar el vector de características a un espacio de vector de características entrenado, en donde el espacio de vector de características comprende un vector de características para el tipo de defecto conocido; y  
 calcular una distancia entre el vector de características y el vector de características para el tipo de defecto conocido, con el fin de obtener la puntuación de similitud de la imagen o imágenes rectangulares para cada tipo de defecto conocido.
- 30 8. El método de detección de defectos (100) según la reivindicación 6 o la reivindicación 7, **caracterizado por que** la realización de la clasificación en la imagen o imágenes rectangulares basándose en la puntuación de similitud comprende:  
 bajo la condición de que una puntuación máxima de similitud de las puntuaciones de similitud no sea inferior a un primer umbral de similitud, emitir un tipo de defecto correspondiente a la puntuación máxima de similitud; o  
 bajo la condición de que las puntuaciones de similitud sean todas inferiores a un primer umbral de similitud, emitir un tipo de defecto desconocido; opcionalmente antes de la salida de un tipo de defecto correspondiente a la puntuación de similitud máxima, el método comprende, además:
- 35 bajo la condición de que el tipo de defecto sea un tipo de defecto especificado, calcular el área de los píxeles de anomalía en la imagen rectangular; en donde  
 la salida de un tipo de defecto correspondiente a la puntuación de similitud máxima comprende:  
 bajo la condición de que el área sea mayor que un umbral de área, emitir el tipo de defecto correspondiente a la puntuación máxima de similitud.
- 40 9. El método de detección de defectos (100) según la reivindicación 8, **caracterizado por que** la salida de un tipo de defecto correspondiente a la puntuación de similitud máxima comprende:  
 bajo la condición de que la puntuación de similitud máxima sea mayor que un segundo umbral de similitud, emitir el tipo de defecto correspondiente a la puntuación de similitud máxima, en donde el segundo umbral de similitud es mayor que el primer umbral de similitud.
- 45 50 10. El método de detección de defectos (100) según una cualquiera de las reivindicaciones anteriores, **caracterizado por que** la información de detección de defectos comprende además una puntuación de similitud correspondiente a un tipo de defecto.
- 55 11. Un aparato de detección de defectos (500), **caracterizado por que** comprende:  
 una unidad de obtención (501) y una unidad de procesamiento (502), en donde la unidad de obtención (501) y la unidad de procesamiento (502) están configuradas para llevar a cabo las etapas del método según una cualquiera de las reivindicaciones 1 - 10.

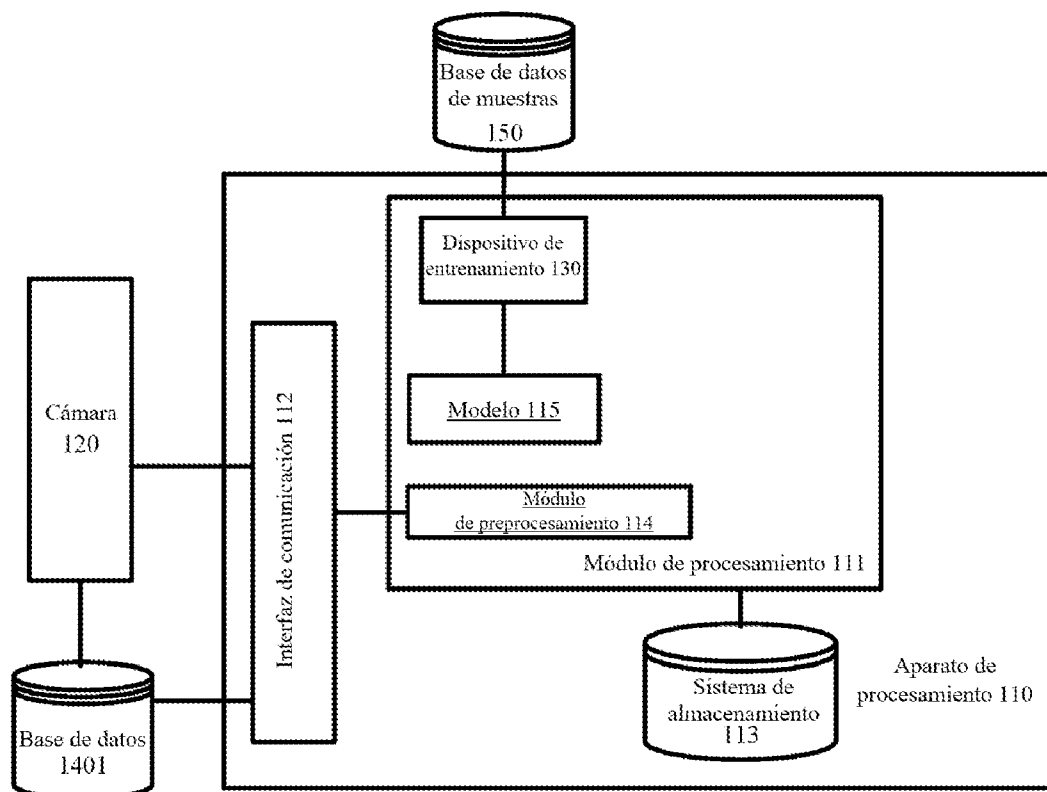


FIG. 1

100

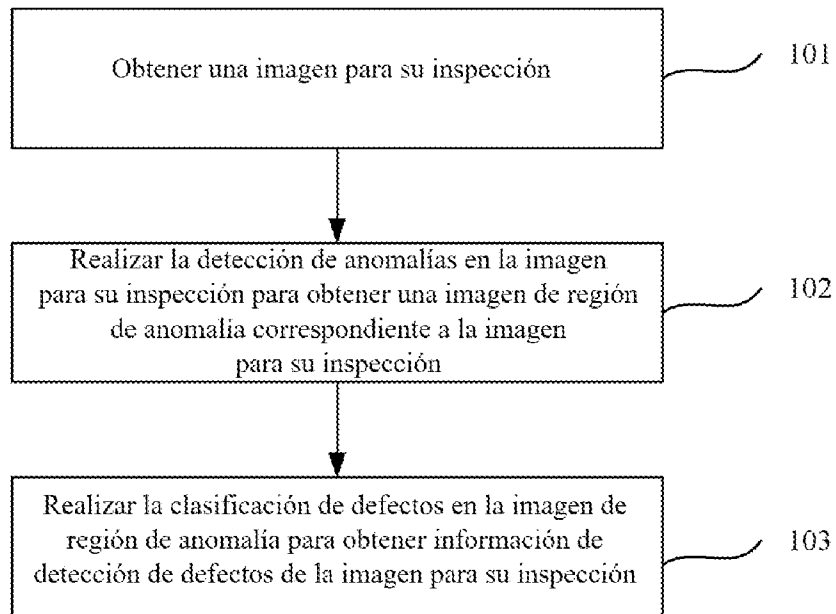


FIG. 2




FIG. 3

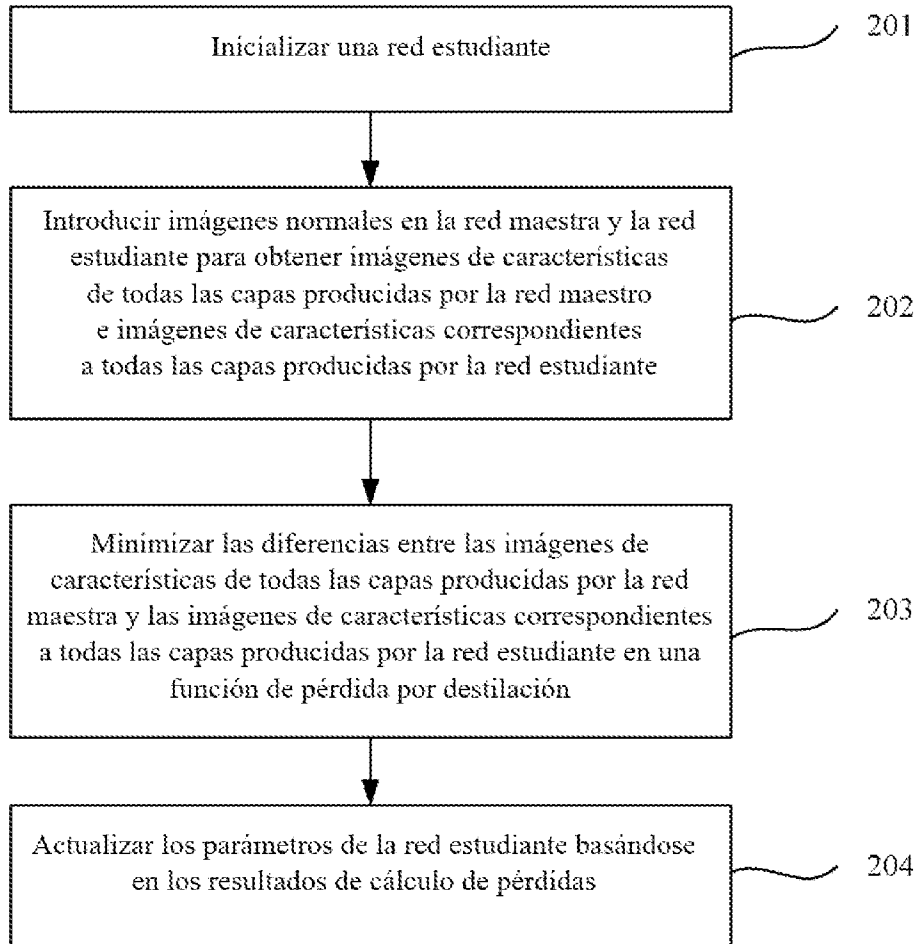
200

FIG. 4




FIG. 5

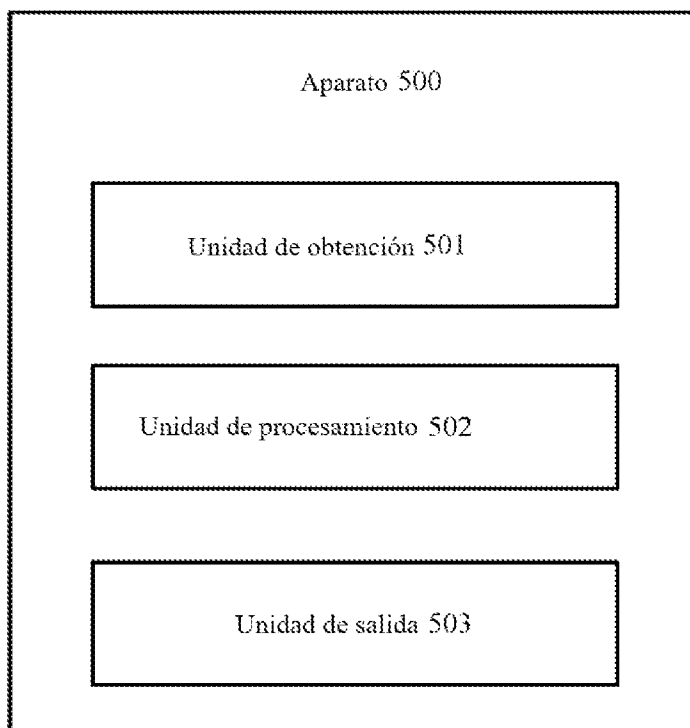


FIG. 6

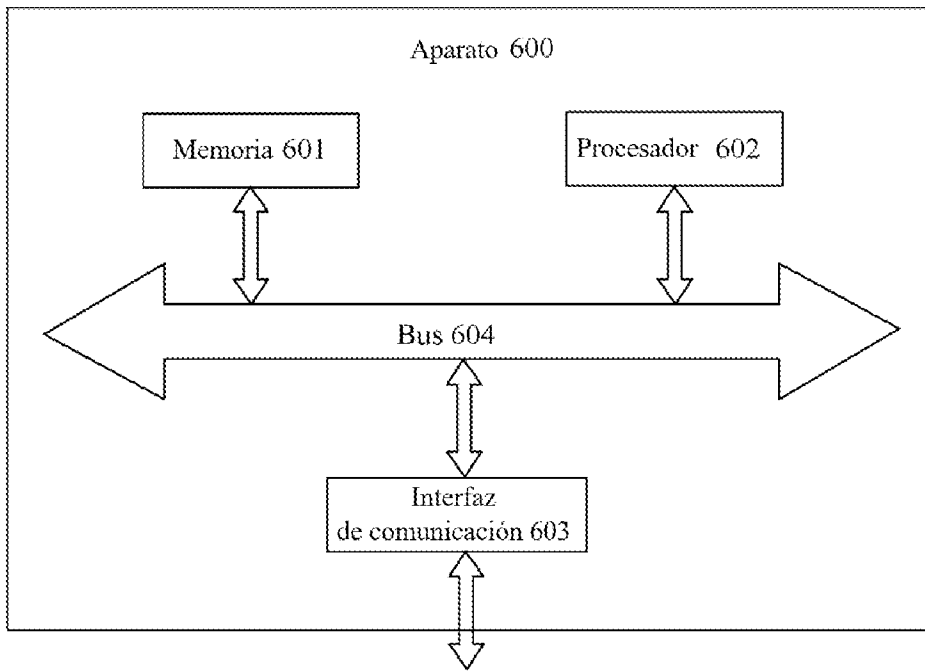


FIG. 7