

19



OFICINA ESPAÑOLA DE
PATENTES Y MARCAS

ESPAÑA



11 Número de publicación: **3 015 707**

51 Int. Cl.:

G06V 10/44	(2012.01)
G06V 10/82	(2012.01)
G06V 20/52	(2012.01)
G06V 30/19	(2012.01)
G06V 30/424	(2012.01)

12

TRADUCCIÓN DE PATENTE EUROPEA

T3

86 Fecha de presentación y número de la solicitud internacional: **09.08.2019 PCT/US2019/046014**

87 Fecha y número de publicación internacional: **13.02.2020 WO20033900**

96 Fecha de presentación y número de la solicitud europea: **09.08.2019 E 19759198 (5)**

97 Fecha y número de publicación de la concesión europea: **25.12.2024 EP 3834129**

54 Título: **Sistemas y métodos para procesar imágenes**

30 Prioridad:

10.08.2018 US 201862717649 P

45 Fecha de publicación y mención en BOPI de la traducción de la patente:
07.05.2025

73 Titular/es:

**LEIDOS SECURITY DETECTION & AUTOMATION,
INC. (100.00%)
One Radcliff Road
Tewksbury MA 01876, US**

72 Inventor/es:

DUJMIC, DENIS

74 Agente/Representante:

SÁEZ MAESO, Ana

ES 3 015 707 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

Sistemas y métodos para procesar imágenes

5 Solicitud relacionada

Esta solicitud reivindica la prioridad y el beneficio de la solicitud de patente provisional de Estados Unidos núm. 62/717,649, presentada el 10 de agosto de 2018.

10 Antecedentes

Las tecnologías de imágenes, que incluyen radiografía, tomografía computarizada, imágenes por resonancia magnética (IRM), tomografía por emisión de positrones (PET) y muchas otras, han encontrado un uso generalizado en aplicaciones tan diversas como la obtención de imágenes médicas y la inspección de carga. La radiografía de rayos X es el método principal de Inspección No Intrusiva (NII) de la carga en la actualidad y se usa junto con las inspecciones humanas.

20 El documento US 2017/242148 A1 describe sistemas y métodos para identificar e informar el contenido de un tanque, contenedor o vehículo. Se proporcionan herramientas programáticas para ayudar a un operador a analizar el contenido de un tanque, contenedor o vehículo. Los datos del manifiesto se importan automáticamente al sistema para cada envío, lo que ayuda de esta manera al personal de seguridad a determinar rápidamente el contenido del contenedor. En caso de un desajuste entre el contenido del contenedor mostrado por los datos del manifiesto y el contenido determinado a partir del sistema de escaneo, el contenedor o vehículo puede retenerse para una inspección adicional.

25 Breve resumen

De acuerdo con un primer aspecto de la presente invención, se proporciona un método implementado en un dispositivo informático para validar un manifiesto de carga asociado con un contenedor de envío de acuerdo con la reivindicación 1. Las características opcionales del método se describen en las reivindicaciones 2 a 8.

30 De acuerdo con un segundo aspecto de la presente invención, se proporciona un sistema para validar un manifiesto de carga asociado con un contenedor de envío de acuerdo con la reivindicación 9. Las características opcionales del sistema se describen en las reivindicaciones 10 a 15.

35 De acuerdo con un tercer aspecto de la presente invención, se proporciona un medio legible por ordenador no transitorio que almacena instrucciones ejecutables por un procesador para validar un manifiesto de carga asociado con un contenedor de envío de acuerdo con la reivindicación 16.

Breve descripción de los dibujos

40 El experto en la técnica entenderá que los dibujos son principalmente con fines ilustrativos y no pretenden limitar el alcance de la materia descrita en la presente descripción. Los dibujos no están necesariamente a escala; en algunos casos, varios aspectos del tema descrito en la presente descripción pueden mostrarse exagerados o ampliados en los dibujos para facilitar la comprensión de las diferentes características. En los dibujos, los caracteres de referencia similares generalmente se refieren a características similares (por ejemplo, elementos funcionalmente similares o estructuralmente similares).

50 Las características y ventajas anteriores y otras proporcionadas por la presente descripción se entenderán más completamente a partir de la siguiente descripción de modalidades ilustrativas cuando se lean junto con los dibujos adjuntos, en los que:

La Figura 1 es un diagrama de bloques que muestra un sistema de procesamiento de imágenes en términos de módulos de acuerdo con una modalidad ilustrativa;

55 La Figura 2 es un diagrama de flujo que ilustra un método ilustrativo empleado por el sistema de procesamiento de imágenes, de acuerdo con una modalidad ilustrativa;

La Figura 3 ilustra una red neuronal autocodificadora ilustrativa empleada por el sistema de procesamiento de imágenes, de acuerdo con una modalidad ilustrativa;

Las Figuras 4A - 4C muestran una imagen de salida proporcionada por el sistema de procesamiento de imágenes, de acuerdo con una modalidad ilustrativa;

60 La Figura 5 ilustra un diagrama de red que representa un sistema para implementar el sistema de procesamiento de imágenes, de acuerdo con una modalidad ilustrativa;

La Figura 6 es un diagrama de bloques de un dispositivo informático ilustrativo que puede usarse para realizar una o más etapas de los métodos proporcionados por las modalidades ilustrativas

65 La Figura 7 ilustra una arquitectura de red neuronal ilustrativa para el análisis de texto de manifiesto de carga, de acuerdo con una modalidad ilustrativa;

La Figura 8 ilustra una implementación ilustrativa de un algoritmo de verificación de manifiesto (MV) para ayudar

a un operador en una decisión de inspección, de acuerdo con una modalidad ilustrativa;

La Figura 9 ilustra una curva de características operador-receptor (ROC) que relaciona la eficiencia de la verificación de manifiestos con la interdicción de carga documentada incorrectamente, de acuerdo con una modalidad ilustrativa;

5 La Figura 10 ilustra una implementación de un algoritmo de validación de contenedor vacío (ECV) que marcó una bolsa de lona llena de moneda en un contenedor declarado vacío, de acuerdo con una modalidad ilustrativa;

La Figura 11 ilustra segmentos de contenedor que se usan para la detección de anomalías, de acuerdo con una modalidad ilustrativa;

10 La Figura 12 ilustra los resultados de una implementación ilustrativa de un algoritmo de detección de anomalías, de acuerdo con una modalidad ilustrativa;

La Figura 13 es un diagrama de flujo que ilustra un método ilustrativo empleado por el sistema de procesamiento de imágenes, de acuerdo con una modalidad ilustrativa; y

La Figura 14 es un diagrama de flujo que ilustra un método ilustrativo empleado por el sistema de procesamiento de imágenes para identificar contenedores de envío vacíos, de acuerdo con una modalidad ilustrativa.

15 Descripción detallada

Hoy en día, las imágenes de la carga se evalúan durante las inspecciones de la carga por el personal de seguridad para la detección de amenazas, el contrabando de sustancias ilegales y la evasión del derecho de aduana. Los escáneres se usan para ayudar en la inspección de la carga, pero tradicionalmente se han usado para examinar solo un pequeño porcentaje del tráfico de carga, ya que las imágenes generadas por el escáner aún requieren significativamente recursos humanos para interpretarlas adecuadamente. En los casos en los que la carga se somete a un escrutinio NII, el análisis de imágenes convencional se basa en la percepción humana, la toma de decisiones y el juicio. La agencia de Aduanas y Protección Fronteriza de los Estados Unidos identificó la vigilancia del operador y la variabilidad de las habilidades entre los operadores como los principales riesgos que pueden socavar el proceso de inspección. Las modalidades de la presente invención ayudan a abordar estos riesgos mediante la introducción de algoritmos de aprendizaje automático para la inspección de carga que pueden reemplazar o ayudar a los operadores para poder lograr una inspección del 100 % de toda la carga.

30 En la presente descripción se describen sistemas, métodos y medios legibles por ordenador de procesamiento de imágenes para procesar imágenes para verificar el contenido de los contenedores e identificar anomalías en las imágenes y los manifiestos. Las modalidades proporcionan un sistema de procesamiento de imágenes que incluye un marco de aprendizaje automático para analizar automáticamente las imágenes y los manifiestos. En algunas modalidades, las imágenes incluyen imágenes radiográficas que pueden obtenerse a través de un escáner o dispositivo de cribado en un punto de control de seguridad. El documento de envío, típicamente llamado manifiesto de envío, es un documento obligatorio que acompaña a un contenedor de carga durante el envío y describe el contenido y la cantidad del contenedor, el origen, el destino, el remitente, las fechas de envío. El documento de envío también puede ser la declaración de aduanas o cualquier documento similar que pueda revelar el contenido del contenedor. Como se usa en la presente, 'manifiesto' puede denotar otros documentos que describen el contenido de la carga en un contenedor de envío además de, o en lugar de, un manifiesto de envío tradicional. Una dificultad con los enfoques de inspección convencionales es la vigilancia de los operadores humanos bajo una pesada carga de inspección y la variabilidad en la decisión entre diferentes operadores. La tarea de un operador humano es comprender el texto del manifiesto, determinar el tipo de carga que se envía, evaluar la imagen radiográfica y determinar si el patrón en la imagen es consistente con el patrón esperado. La inspección puede ser difícil ya que, por ejemplo, el documento de envío (manifiesto) puede contener nombres comerciales, palabras en idiomas extranjeros y/o términos profesionales (químicos) que pueden no ser comprensibles para el operador. Por lo tanto, el operador puede no conocer el tipo de carga en el contenedor bajo inspección. Otro desafío es comprender cómo debería verse el patrón de imagen de rayos X para un tipo de carga dada. Los contenedores están típicamente completamente llenos de carga para optimizar el costo de envío. Los objetos individuales se superponen con otros objetos en la imagen de transmisión radiográfica, por lo tanto, las formas de los objetos individuales a menudo no son reconocibles y solo se usa el patrón de grupo de la carga para evaluar la consistencia. Por ejemplo, un operador puede reconocer la forma de una sola botella de vidrio en la imagen radiográfica, pero en una carga de contenedor completo de botellas de vidrio vacías las formas de las botellas individuales no son reconocibles, pero el operador debe confiar en el patrón del grupo.

55 Los expertos en la técnica entienden la dificultad de analizar imágenes radiográficas en comparación con las imágenes fotográficas. Las imágenes radiográficas se forman mediante la creación de rayos X con una fuente de rayos X que se colima para formar un haz de abanico estrecho, que pasa carga a través del haz y que detecta rayos X que pasan a través de la carga. Dado que la imagen del objeto se crea a partir de rayos X que se transmiten a través de múltiples objetos de carga, la imagen contiene perfiles radiográficos superpuestos de todos los objetos en el haz en un momento dado. Por lo tanto, a diferencia de una imagen fotográfica que muestra solo objetos en la parte delantera, una imagen radiográfica muestra múltiples objetos superpuestos que hacen que el reconocimiento de objetos individuales sea más desafiante.

65 En modalidades ilustrativas, el sistema de procesamiento de imágenes incluye un dispositivo informático equipado con un procesador en comunicación con un escáner, tal como, pero sin limitarse a, un escáner de radiografía de rayos X, configurado para renderizar imágenes radiográficas. Como se analiza más abajo, el dispositivo informático se

configura para entrenar un algoritmo(s) de aprendizaje automático con un conjunto de datos de entrenamiento que incluye al menos una imagen radiográfica para generar al menos un vector de características. La imagen radiográfica incluye al menos una imagen de un contenedor de prueba que almacena objetos. El contenedor de prueba puede contener uno o más objetos o estar vacío. Los objetos pueden incluir un objeto o muchos objetos del mismo tipo. En modalidades ilustrativas, el(los) algoritmo(s) de aprendizaje automático es una red neuronal autocodificadora (G.E. Hinton y R.R. Salakhutdinov. Reducing the dimensionality of data with neural networks. Science, 313(5786):504, 2006). Después de que el(los) algoritmo(s) de aprendizaje automático se entrena(n) como se describe más abajo, el dispositivo informático recibe al menos una imagen radiográfica renderizada del escáner. La imagen radiográfica renderizada representa un contenedor que contiene objetos de un cierto tipo o puede estar vacío. En una modalidad, el dispositivo informático verifica un documento de manifiesto de envío que enumera el(los) objeto(s) en el contenedor, verifica que el contenedor está vacío o identifica un objeto o una anomalía mediante el uso de al menos un vector de características. El dispositivo informático genera una indicación de detección automatizada.

Un(os) algoritmo(s) de aprendizaje automático para el análisis de imágenes de imágenes radiográficas de contenedores de envío se ejecuta en una plataforma o marco de aprendizaje automático que emplea una red neuronal autocodificadora. Algunas ventajas de usar un marco de red neuronal de tipo autocodificador sobre otros métodos es que requiere un menor número de imágenes para el entrenamiento, puede entrenarse con datos en vivo en tiempo real, puede usarse para etiquetar imágenes y puede usarse para el autoaprendizaje. En consecuencia, el(los) algoritmo(s) de aprendizaje automático se basa(n) en una red neuronal autocodificadora y usa imágenes radiográficas de contenedores para los datos de entrenamiento. El entrenamiento minimiza la diferencia entre el vector de imagen

de entrada y la imagen reconstruida en cada muestra de entrenamiento,
$$n \cdot \min \sum_{n=1}^N \Delta(B \cdot A \cdot x_n, x_n)$$
, donde A y B son las partes codificadora y decodificadora de la red, respectivamente, x es el vector de imagen de entrada (ver Figura 3 analizada más abajo), y Δ es la distancia euclidiana al cuadrado en el espacio de características que se usa como función de pérdida en el entrenamiento. Los parámetros de A y B se determinan en el entrenamiento mediante el uso de un método de retropropagación estándar. En la segunda parte del entrenamiento, el vector de características de contenedores con el mismo tipo de objeto se promedia para obtener los datos de calibración. Los tipos de objetos que se promedian pueden incluir, por ejemplo, contenedores con cajas de cerveza, refrigeradores o motocicletas. Sin embargo, el tipo de objeto puede ser cualquier objeto u objetos transportables en un contenedor. Los datos de calibración contienen la media, $\langle A(x) \rangle$, y la desviación estándar, $\langle (A^2(x)) - (A(x))^2 \rangle$, de los vectores de características para la muestra, donde el promedio se indica con corchetes angulares. Este procedimiento supone que los parámetros de características se describen con la distribución normal (gaussiana). Si este no es el caso, la misma muestra de carga se describe con más de una media y desviación estándar de manera que la función de densidad de probabilidad de la muestra se aproxima con una serie de aproximaciones gaussianas. De esta manera, incluso las formas complejas pueden describirse con un número relativamente pequeño de parámetros.

El(los) algoritmo(s) de aprendizaje automático entrenado(s) genera(n) uno o más vectores de características en base al conjunto de datos de entrenamiento. Los vectores de características se usan para representar características numéricas o simbólicas, llamadas características, de un objeto de una manera matemática, y se usan para el procesamiento de patrones. El conjunto de datos de entrenamiento se usa para entrenar el sistema de procesamiento de imágenes para identificar patrones asociados con el tipo de objeto. Los patrones generados se almacenan y se usan para analizar vectores de características de una o más imágenes de entrada. Las imágenes de entrada son imágenes de objetos obtenidas a través de una máquina radiográfica. En base a los vectores de características, en una modalidad, el sistema de procesamiento de imágenes es capaz de identificar anomalías.

Un segundo tipo de algoritmo(s) de red neuronal artificial se usa para analizar la documentación de envío (manifiesto) mediante el uso de algoritmos de procesamiento de lenguaje natural. En modalidades ilustrativas, el algoritmo se basa en una red neuronal de tipo palabra a vector, también conocida como incrustación de palabras, (tal como, pero sin limitarse a, tipos de palabras a vector tales como los descritos en Mikolov, Tomas; y otros (2013)). "Efficient Estimation of Word Representations in Vector Space". arXiv: 1301.3781; ver Figura 7 se analiza más adelante a continuación. El enfoque crea un diccionario de palabras manifiestas y etiquetas asociadas, y encuentra la correlación entre las palabras y las etiquetas. Las palabras se transforman en un nuevo espacio de vectores de características donde las palabras correlacionadas tienen vectores de características similares (la capa oculta en la Figura 3). El procedimiento

de entrenamiento minimiza la función de pérdida, por ejemplo, definida como:
$$\min \sum_{n=1}^N -\log \left(s(v_n^T \cdot x'_n) \right)$$
, donde x' es la suma de los vectores de palabras de salida de la muestra del manifiesto n, A y B son partes del codificador y el decodificador de la red que convierten el vector de palabra de entrada como $x' = B \cdot A \cdot x$, y y es el

vector de palabras para una etiqueta, s es la función softmax
$$e^{x^T \cdot x'} / \sum_j e^{x_j^T \cdot x'}$$
. El entrenamiento minimiza la función de pérdida mediante el uso de métodos estándar de retropropagación y descenso de gradiente para determinar los parámetros de las matrices A y B. Los expertos en la técnica saben que en lugar de usar palabras manifiestas sin procesar es mejor usar una combinación de palabras o segmentos de palabras. Las palabras comunes que aparecen en todas las categorías de carga ('el', 'origen', 'destino', 'peso'...) tienen poco poder de discriminación y pueden ignorarse.

5 El sistema de procesamiento de imágenes y/o manifiestos descrito en la presente descripción analiza imágenes radiográficas y/o manifiestos para verificar el contenido de los contenedores e identificar anomalías en las imágenes y/o manifiestos. Las modalidades pueden realizar la verificación de manifiesto (MV) para verificar que los objetos enumerados en el manifiesto correspondan con los objetos en los contenedores, para realizar la verificación de contenedor vacío (ECV) para verificar que los contenedores estén vacíos, para determinar un tipo de carga o para realizar la detección de tipo de objeto, para buscar objetos y/o amenazas específicas, y/o para realizar la detección de anomalías para buscar patrones extraños. Cada tipo de análisis se explica más abajo.

10 Debe apreciarse que el análisis de imágenes radiográficas de contenedores de envío descrito en la presente descripción puede realizarse de forma aislada o junto con el análisis del manifiesto de carga. En algunas modalidades, las técnicas para el análisis de manifiestos de carga descritas en la presente descripción, tales como, pero sin limitarse a, aquellas que usan incrustación de palabras, también pueden realizarse de forma aislada (es decir, sin realizar análisis de imágenes radiográficas) para determinar el contenido de los contenedores de envío.

15 Verificación de manifiesto (MV)

La verificación de manifiesto (MV) intenta verificar que lo que hay en el contenedor de envío es lo mismo que indica el manifiesto que debe estar en el contenedor de envío. La MV se realiza mediante el procesamiento del texto del manifiesto de envío con el sistema de procesamiento de manifiestos y el procesamiento de la imagen radiográfica con el sistema de procesamiento de imágenes. Tanto el sistema de procesamiento de imágenes como el de manifiesto derivan vectores de características que son similares para la misma categoría de carga. Por ejemplo, los vectores de características de imagen para carga con botellas vacías son similares, mientras que son diferentes de otra carga debido a un patrón específico que las botellas vacías hacen en la imagen radiográfica. La descripción de la carga de botellas vacías en el manifiesto es similar para los envíos de botellas vacías, por lo que el vector de características del manifiesto es específico para esta categoría de carga. MV compara la correlación entre vectores de características de imagen y manifiesto con datos históricos.

30 En algunas modalidades, el manifiesto se analiza primero para determinar la categoría de carga. El sistema de procesamiento de imágenes verifica el(los) patrón(es) de la imagen para determinar la consistencia con imágenes históricas para esta categoría de carga, lo que da como resultado el valor de chi cuadrado, como se describió anteriormente. El algoritmo puede optar por validar envíos con un valor de chi cuadrado menor que un umbral. El umbral puede establecerse de manera que la inspección cumpla con la tasa de falsas alarmas requerida para una tasa de eficiencia de verificación dada. Por ejemplo, una implementación del algoritmo MV requiere que al 80 % de la tasa de verificación manifiesta el 70 % de la carga documentada falsamente debe interdictarse. Las curvas de características del operador-receptor para 200 categorías de carga de un puerto marítimo (representadas en la Figura 9) muestran la relación entre la eficiencia y la tasa de interdicción.

40 En algunas modalidades, el procesamiento de imágenes se realiza primero para determinar la categoría de carga, y el procesamiento del manifiesto deriva un vector de características que se usa para comparar con la distribución histórica.

45 En algunas modalidades, la categoría de carga no se asigna, pero los vectores de características de manifiesto e imagen se combinan en un espacio grande. Por ejemplo, el vector de características de imagen con un espacio de 20 dimensiones y el vector de características del manifiesto en un espacio de 100 dimensiones se combinan en un espacio de 120 dimensiones. En lugar de buscar clústeres por separado en los espacios de manifiesto e imagen, se realiza una verificación de que los datos son consistentes con los escaneos limpios históricos en un espacio de 120 dimensiones. No tener que colocar la carga en una categoría permite el aprendizaje semisupervisado y continuo.

50 En algunas modalidades, el sistema de procesamiento de imágenes usa el vector de características para clasificar imágenes radiográficas para la inspección del operador.

55 El sistema de procesamiento de imágenes determina una probabilidad estadística de que el contenido del contenedor de envío coincida con el manifiesto mediante la comparación del vector de características extraído de la imagen radiográfica del contenedor de envío con una distribución histórica de vectores de características anteriores de imágenes radiográficas de contenedores de envío anteriores asociados con manifiestos de carga que enumeran un objeto similar a los supuestamente en el contenedor de envío bajo examen. Como ejemplo no limitativo, el sistema 100 puede generar una probabilidad estadística de que el contenido del contenedor de envío coincida con los objetos enumerados en el manifiesto de carga asociado en base al grado de coincidencia entre el vector de características extraído y la distribución histórica de vectores de características anteriores mediante el uso de criterios predeterminados. Por ejemplo, un 85 % de coincidencia entre el vector de características extraído y la distribución histórica de vectores de características puede equivaler directamente a que el sistema 100 asigne una probabilidad del 85 % de que el contenido del contenedor de envío coincida con el manifiesto de carga asociado o puede equivaler a una probabilidad menor o mayor que se asigne en base a datos históricos anteriores adquiridos por el sistema.

65 En algunas modalidades, el sistema de procesamiento de imágenes determina que un parámetro que cuantifica el contenido del contenedor (por ejemplo, objetos de un tipo de objeto) coincide con el manifiesto. El parámetro se

muestra gráficamente contra una distribución de los parámetros históricos para el tipo de objeto y se presenta al operador.

5 En algunas modalidades, el sistema de procesamiento de manifiestos ayuda a un operador a comprender el significado del texto del manifiesto. Como se mencionó anteriormente, el manifiesto puede contener términos comerciales o profesionales que no son conocidos por el operador. El procesamiento de manifiestos determina la categoría de carga en base a la proximidad del vector de características con la distribución histórica de manifiestos de carga etiquetados. La determinación de la categoría de carga es una parte de la asistencia al operador. En algunas modalidades, el sistema de procesamiento de imágenes ayuda a los operadores a comprender el patrón esperado en la imagen radiográfica. Como se describió anteriormente, los contenedores están típicamente llenos de carga y las formas de objetos individuales pueden no ser reconocibles, pero en su lugar los operadores confían en el patrón grupal. El procesamiento de imágenes encuentra el patrón de imagen esperado para la categoría de carga en base a datos históricos. La visualización de imágenes históricas similares es parte de una función de asistencia al operador que puede mostrar imágenes históricas elegidas aleatoriamente para esta categoría de carga o imágenes que son las más cercanas a la imagen bajo inspección (ver la Figura 8 por ejemplo).

15 En algunas modalidades, el sistema de procesamiento de imágenes actualiza la distribución histórica de vectores de características en tiempo real con cada imagen nueva.

20 En algunas modalidades, la distribución histórica de vectores de características se basa en menos de 10 exploraciones radiográficas y manifiestos correspondientes.

La red neuronal artificial es una red neuronal de autocodificación.

25 En algunas modalidades, la red neuronal artificial es una red neuronal no supervisada.

Verificación de contenedor vacío (ECV)

30 La verificación de contenedores vacíos se realiza mediante el sistema de procesamiento de imágenes descrito en la presente descripción mediante la inspección de imágenes radiográficas de un contenedor vacío. El sistema de procesamiento de imágenes recibe una imagen radiográfica renderizada que incluye un contenedor que se declara vacío. El sistema de procesamiento de imágenes divide la imagen en uno o más segmentos que se analizan mediante el uso de una red neuronal de tipo autocodificador para extraer un vector de características. El sistema de procesamiento de imágenes compara el vector de características contra la distribución histórica de vectores de características para el segmento de contenedor correspondiente. La verificación de contenedores vacíos busca objetos dentro de un contenedor vacío de cualquier otra manera. El sistema de procesamiento de imágenes usa el vector de características para confirmar que el contenedor declarado vacío está efectivamente vacío.

40 En algunas modalidades, el sistema de procesamiento de imágenes usa el vector de características para clasificar imágenes radiográficas de contenedores declarados vacíos para la inspección del operador.

En algunas modalidades, el sistema de procesamiento de imágenes asigna una probabilidad estadística de que el contenedor esté vacío.

45 En algunas modalidades, el sistema de procesamiento de imágenes determina un parámetro que cuantifica que el contenedor está vacío, que se muestra gráficamente contra una distribución de parámetros históricos para contenedores vacíos y se presenta al operador.

50 En algunas modalidades, el sistema de procesamiento de imágenes actualiza la distribución histórica de vectores de características para cada segmento en tiempo real con cada imagen radiográfica de contenedor vacío.

En algunas modalidades, la distribución histórica de vectores de características se basa en menos de 10 exploraciones radiográficas.

55 En algunas modalidades, los objetos encontrados en contenedores declarados vacíos se marcan para la verificación del operador (ver, por ejemplo, la Figura 10).

Detección de anomalías

60 La detección de anomalías se realiza mediante el sistema de procesamiento de imágenes descrito en la presente descripción y mediante la inspección de imágenes radiográficas de un contenedor para detectar una anomalía. El sistema de procesamiento de imágenes divide la imagen en uno o más segmentos (por ejemplo, como se muestra en la Figura 11) que se analizan mediante el uso de una red neuronal de tipo autocodificador para extraer vectores de características para cada segmento. El sistema de procesamiento de imágenes compara cada vector de características contra la distribución de otros vectores de características del contenedor. El sistema de procesamiento de imágenes usa el vector de características para identificar segmentos que son significativamente diferentes del resto

de la imagen. Por ejemplo, la Figura 12, se describe más abajo, muestra la diferencia de chi-cuadrado del vector de características de la media de otros segmentos.

5 En algunas modalidades, el sistema de procesamiento de imágenes usa el vector de características para clasificar imágenes radiográficas para la inspección del operador.

En algunas modalidades, el sistema de procesamiento de imágenes asigna una probabilidad estadística de que el segmento del contenedor tenga una anomalía.

10 En algunas modalidades, el sistema de procesamiento de imágenes determina un parámetro que cuantifica una probabilidad de que el segmento de contenedor tenga una anomalía, que se muestra gráficamente contra la distribución de parámetros para los segmentos de contenedor y se presenta al operador.

Monitoreo de la calidad de los datos

15 El monitoreo de la calidad de los datos se realiza mediante el sistema de procesamiento de imágenes descrito en la presente descripción mediante el análisis de imágenes radiográficas para el monitoreo de la calidad de los datos. El sistema de procesamiento de imágenes divide una imagen en uno o más segmentos que se analizan mediante el uso de una red neuronal de tipo autocodificador para extraer uno o más vectores de características para cada segmento.
20 El sistema de procesamiento de imágenes compara cada vector de características con los vectores de características de distribución histórica para el segmento. El sistema de procesamiento de imágenes usa los vectores de características para evaluar la calidad de los datos de la imagen radiográfica, tales como canales detectores defectuosos, imágenes cortadas e imágenes con dosis de radiación incorrecta.

25 Detección de tipo de carga

La detección del tipo de carga se realiza mediante el sistema de procesamiento de imágenes descrito en la presente descripción mediante el análisis de imágenes radiográficas de uno o más objetos bajo inspección. El sistema de procesamiento de imágenes analiza las imágenes mediante el uso de una red neuronal de tipo artificial para extraer
30 un vector de características. Cada vector de características se compara con vectores de características de distribución históricos para el segmento y los vectores de características se usan para clasificar cada uno de los uno o más objetos que se escanean.

35 En cada una de las acciones descritas anteriormente, puede incluirse una etiqueta en una imagen de salida generada por el sistema de procesamiento de imágenes que identifica una anomalía u objeto en la imagen analizada. En algunas modalidades, la ubicación de la anomalía u objeto se indica o resalta en una imagen de salida. En otra modalidad, el sistema de procesamiento de imágenes puede usarse para indicar visual o auditivamente al personal de seguridad que el contenedor incluye una anomalía y/o no coincide con el manifiesto.

40 Las modalidades pueden usarse en varias aplicaciones de seguridad, tales como, pero sin limitarse a, aplicaciones en las que el personal de seguridad evalúa imágenes de contenedores en busca de amenazas. Por ejemplo, el sistema de procesamiento de imágenes descrito en la presente descripción puede usarse por la Aduana y Protección de Fronteras en los puertos para verificar los contenedores en un punto de control de seguridad. El sistema de procesamiento de imágenes también puede usarse por la Aduana y la Protección de Fronteras para escanear
45 contenedores. El sistema de procesamiento de imágenes también puede usarse para verificar la carga en vehículos de transporte o entrega.

Después de haber descrito una descripción general y los beneficios de las modalidades anteriores, ahora se proporcionan más detalles específicos de las modalidades con respecto a las figuras más abajo.

50 La Figura 1 es un diagrama de bloques que muestra un sistema de procesamiento de imágenes 100 en términos de módulos de acuerdo con una modalidad ilustrativa. Uno o más de los módulos pueden implementarse mediante el uso del dispositivo 510, el dispositivo de escaneo 520, el servidor 530 y/o la base de datos 540, como se muestra en la Figura 5. Los módulos incluyen un módulo de algoritmo de aprendizaje automático 110, un módulo de conjunto de datos de entrenamiento 120, un módulo de datos de entrada 130 y un módulo de datos de salida 140. Los módulos pueden incluir varios circuitos, circuitos integrados y uno o más componentes de software, programas, aplicaciones u otras unidades de código base o instrucciones configuradas para ser ejecutadas por uno o más procesadores. En algunas modalidades, uno o más de los módulos 110, 120, 130, 140 pueden incluirse en el servidor 530, mientras que otros de los módulos 110, 120, 130, 140 se proporcionan en el dispositivo 510 o el dispositivo de escaneo 520. Aunque los módulos 110, 120, 130 y 140 se muestran como módulos distintos en la Figura 1, debe entenderse que los módulos 110, 120, 130 y 140 pueden implementarse como menos o más módulos que los ilustrados. Debe entenderse que cualquiera de los módulos 110, 120, 130 y 140 puede comunicarse con uno o más componentes incluidos en el sistema 500 (Figura 5), tal como el dispositivo 510, el dispositivo de escaneo 520, el servidor 530 o la(s) base(s) de datos 540.

65 El módulo de algoritmo de aprendizaje automático 110 puede ser un módulo implementado en software y/o hardware configurado para ejecutar o ejecutar un(os) algoritmo(s) de aprendizaje automático, y puede almacenar y gestionar

parámetros, variables, datos y otros componentes necesarios para ejecutar el(los) algoritmo(s) de aprendizaje automático. El(los) algoritmo(s) de aprendizaje automático es una red neuronal de tipo autocodificador 110A usada para realizar análisis de imágenes de imágenes radiográficas de un contenedor de envío o una red neuronal recurrente 110B usada para realizar análisis de manifiestos de carga asociados con un contenedor de envío.

5 El módulo 120 del conjunto de datos de entrenamiento puede ser un módulo implementado en software y/o hardware configurado para gestionar y almacenar un conjunto de datos de entrenamiento para el(los) algoritmo(s) de aprendizaje automático empleado(s) por el sistema de procesamiento de imágenes 100. En una modalidad ilustrativa, el conjunto de datos de entrenamiento incluye imágenes de contenedores obtenidas mediante el uso de una máquina o dispositivo de cribado radiográfico. Las imágenes pueden representar contenedores que almacenan uno o más objetos.

10 El módulo de datos de entrada 130 puede ser un módulo implementado en software y/o hardware configurado para gestionar y almacenar imágenes de entrada que se analizan mediante el sistema de procesamiento de imágenes 100.

15 El módulo de datos de salida 140 puede ser un módulo implementado en software y/o hardware configurado para gestionar y almacenar la salida del(de los) algoritmo(s) de aprendizaje automático. En algunas modalidades, la salida es una indicación de si la imagen de entrada incluye una anomalía. En una modalidad ilustrativa, la salida es una imagen de salida que indica la presencia de la anomalía resaltando o enfatizando visualmente la anomalía en la imagen de salida. En una modalidad, la imagen de salida puede incluir una etiqueta que identifica la anomalía. En otro ejemplo de modalidad, la salida es una alarma o alerta generada en una máquina o dispositivo de detección de seguridad para indicar a un operador o personal de seguridad que el contenedor incluye una anomalía y/o no coincide con el manifiesto en base al análisis de las imágenes.

20 Se debe apreciar que los módulos de la Figura 1 pueden proporcionar parte o toda la funcionalidad descrita anteriormente con respecto a la imagen radiográfica y el análisis de manifestación. Como se analizó anteriormente, el(los) algoritmo(s) de aprendizaje automático se basa(n) en una red neuronal autocodificadora y usa imágenes radiográficas de contenedores para los datos de entrenamiento. El entrenamiento minimiza la diferencia entre el vector

25 de imagen de entrada y la imagen reconstruida en cada muestra de entrenamiento,
$$n: \min \sum_{n=1}^N \Delta(B \cdot A \cdot x_n, x_n)$$
, donde A y B son las partes codificadora y decodificadora de la red, respectivamente, x es el vector de imagen de entrada (ver la Figura 3 que se analizan más abajo), y Δ es la distancia euclidiana al cuadrado en el espacio de vectores de características que se usa como función de pérdida en el entrenamiento. Los parámetros de A y B se determinan en el entrenamiento mediante el uso de un método de retropropagación estándar. En la segunda parte del entrenamiento, el vector de características de contenedores con el mismo tipo de objeto se promedia para obtener los datos de calibración. Los tipos de objetos que se promedian pueden incluir, por ejemplo, contenedores con cajas de cerveza, refrigeradores o motocicletas. Sin embargo, el tipo de objeto puede ser cualquier objeto u objetos transportables en un contenedor. Los datos de calibración contienen la media, $\langle A(x) \rangle$, y la desviación estándar, $\langle \langle A^2(x) \rangle - (A(x))^2 \rangle$, de los vectores de características para la muestra, donde el promedio se indica con corchetes angulares. Este procedimiento supone que los parámetros de características se describen con la distribución normal (Gaussiana). Si este no es el caso, la misma muestra de carga se describe con más de una media y desviación estándar de manera que la función de densidad de probabilidad de la muestra se aproxima con una serie de aproximaciones gaussianas. De esta manera, incluso las formas complejas pueden describirse con un número relativamente pequeño de parámetros.

45 El(los) algoritmo(s) de aprendizaje automático entrenado(s) genera(n) uno o más vectores de características en base al conjunto de datos de entrenamiento. Los vectores de características se usan para representar características numéricas o simbólicas, llamadas características, de un objeto de una manera matemática, y se usan para el procesamiento de patrones. El conjunto de datos de entrenamiento se usa para entrenar el sistema de procesamiento de imágenes para identificar patrones asociados con el tipo de objeto. Los patrones generados se almacenan y se usan para analizar vectores de características de una o más imágenes de entrada. Las imágenes de entrada son imágenes de objetos obtenidas a través de una máquina radiográfica. En base a los vectores de características, en una modalidad, el sistema de procesamiento de imágenes es capaz de identificar anomalías.

55 Un segundo tipo de algoritmo(s) de red neuronal artificial se usa para analizar la documentación de envío (manifiesto) mediante el uso de algoritmos de procesamiento de lenguaje natural. En modalidades ilustrativas, el algoritmo se basa en una red neuronal de tipo palabra a vector, también conocida como incrustación de palabras, (tal como, pero sin limitarse a, tipos de palabras a vector tales como los descritos en Mikolov, Tomas; y otros (2013). "Efficient Estimation of Word Representations in Vector Space". arXiv: 1301.3781); ver la Figura 7 se analiza más adelante a continuación. El enfoque crea un diccionario de palabras manifiestas y etiquetas asociadas, y encuentra la correlación entre las palabras y las etiquetas. Las palabras se transforman en un nuevo espacio de vectores de características donde las palabras correlacionadas tienen vectores de características similares (la capa oculta en la Figura 3). El procedimiento

60 de entrenamiento minimiza la función de pérdida, por ejemplo, definida como:
$$\min \sum_{n=1}^N -\log \left(s(y_n^T \cdot x'_n) \right)$$
, donde x' es la suma de vectores de palabras de salida de la muestra del manifiesto n , A y B son partes del codificador y decodificador de la red que convierten el vector de palabra de entrada como $x' = B \cdot A \cdot x$, y y es el vector de palabras

para una etiqueta, s es la función softmax $e^{x_j^T x'} / \sum_j e^{x_j^T x'}$. El entrenamiento minimiza la función de pérdida mediante el uso de métodos estándar de retropropagación y descenso de gradiente para determinar los parámetros de las matrices A y B . Los expertos en la técnica saben que en lugar de usar palabras manifiestas sin procesar es mejor usar una combinación de palabras o segmentos de palabras. Las palabras comunes que aparecen en todas las categorías de carga ('el', 'origen', 'destino', 'peso'...) tienen poco poder de discriminación y pueden ignorarse.

El sistema de procesamiento de imágenes y/o manifiestos descrito en la presente descripción analiza imágenes radiográficas y/o manifiestos para verificar el contenido de los contenedores e identificar anomalías en las imágenes y/o manifiestos. Las modalidades pueden realizar la verificación de manifiesto (MV) para verificar que los objetos enumerados en el manifiesto correspondan con los objetos en los contenedores, para realizar la verificación de contenedor vacío (ECV) para verificar que los contenedores estén vacíos, para determinar un tipo de carga o para realizar la detección de tipo de objeto, para buscar objetos y/o amenazas específicas, y/o para realizar la detección de anomalías para buscar patrones extraños.

La Figura 2 es un diagrama de flujo que ilustra un procedimiento ilustrativo 200 empleado por el sistema de procesamiento de imágenes, de acuerdo con una modalidad ilustrativa. El método 200 puede realizarse mediante el uso de uno o más módulos del sistema 100 descrito anteriormente.

En el bloque 202, el(los) algoritmo(s) de aprendizaje automático empleado(s) en el sistema de procesamiento de imágenes 100 se entrena(n) para analizar un tipo de objeto específico dentro de un contenedor mediante el uso de un conjunto de datos de entrenamiento. El módulo de algoritmo de aprendizaje automático 110 puede configurarse para ejecutar el(los) algoritmo(s) de aprendizaje automático. El módulo de datos de entrenamiento 120 puede configurarse para proporcionar el conjunto de datos de entrenamiento al módulo de algoritmo de aprendizaje automático 110 para el entrenamiento.

En una modalidad ilustrativa, el conjunto de datos de entrenamiento incluye al menos una imagen radiográfica de un contenedor que contiene un tipo de objeto especificado. Por ejemplo, el conjunto de datos de entrenamiento puede incluir una imagen radiográfica de un contenedor que contiene refrigeradores. El conjunto de datos de entrenamiento puede usarse para entrenar el(los) algoritmo(s) de aprendizaje automático para identificar una anomalía en una imagen radiográfica. Por ejemplo, el conjunto de datos de entrenamiento puede usarse para entrenar el(los) algoritmo(s) de aprendizaje automático para determinar si una imagen radiográfica de un contenedor que contiene refrigeradores contiene una anomalía.

En un ejemplo no limitativo, las imágenes para el conjunto de datos de entrenamiento se obtienen de un dispositivo de escaneo instalado en un punto de control de seguridad en una instalación, tal como un puerto o control fronterizo, una estación de peaje de carretera, y similares.

En una modalidad de ejemplo, el conjunto de datos de entrenamiento puede incluir imágenes 2D o 3D. En otro ejemplo, el conjunto de datos de entrenamiento puede incluir múltiples imágenes 2D que representan diferentes capas de un objeto. Las imágenes 2D pueden ser imágenes en secciones transversales o segmentos de un objeto. En otro ejemplo más, el conjunto de datos de entrenamiento puede incluir múltiples imágenes, cada una de las cuales representa una perspectiva diferente de un objeto.

En el bloque 204, el módulo de datos de entrada 130 recibe al menos una imagen radiográfica renderizada que incluye un contenedor.

En una modalidad, el sistema de procesamiento de imágenes 100 analiza la imagen de entrada e identifica la presencia de una anomalía al dividir la imagen de entrada en uno o más segmentos que se analizan mediante el uso de una red neuronal de tipo autocodificador para extraer vectores de características para cada segmento. Cada vector de características se compara con la distribución de otros vectores de características de este contenedor. El vector de características se usa para identificar segmentos que son significativamente diferentes del resto de la imagen.

En el bloque 206, el módulo de algoritmo de aprendizaje automático 110 se configura para analizar la imagen de entrada recibida en el bloque 204, y determinar automáticamente si la imagen de entrada es consistente con un documento de manifiesto que enumera el tipo de objeto en el contenedor, si la imagen de entrada es consistente con un contenedor vacío, si la imagen de entrada incluye un objeto, o si la imagen de entrada incluye una anomalía. Por ejemplo, el sistema de procesamiento de imágenes 100 puede determinar que la imagen de entrada incluye una anomalía dentro de un refrigerador.

En el bloque 208, el módulo de datos de salida 140 genera una indicación de detección automatizada en base al análisis de la etapa 106. Por ejemplo, la indicación de detección automatizada puede asociarse con una anomalía identificada en la imagen de entrada. En una modalidad ilustrativa, la indicación de detección automatizada es una etiqueta de texto u otra indicación gráfica que identifica la anomalía en la imagen de entrada. La indicación de detección automatizada puede mostrarse o incluirse en una imagen de salida proporcionada en una pantalla de un dispositivo

de usuario. La imagen de salida puede ser la imagen de entrada (por ejemplo, una imagen radiográfica renderizada) con una indicación de la presencia de la anomalía. Como se describe en la presente descripción, el dispositivo de usuario donde la salida o la indicación de detección automatizada se proporciona al usuario puede incluir un dispositivo de visualización acoplado comunicativamente a un dispositivo de escaneo de seguridad, un dispositivo informático o un servidor. En otra modalidad, la indicación de detección automatizada puede ser una indicación visual que indica la ubicación de la anomalía en la imagen de entrada. Tal indicación visual puede ser una forma de caja de color que encierra la anomalía. En otra modalidad, la indicación de detección automatizada puede ser una indicación gráfica y/o una indicación audible que alerta a un usuario de que se detecta una anomalía en la imagen de entrada. En otra modalidad, la indicación de detección automatizada puede indicar si la imagen de entrada es consistente con el documento de manifiesto o si la imagen de entrada es consistente con un contenedor vacío.

La indicación de detección automatizada puede transmitirse a un dispositivo de usuario o un dispositivo informático acoplado a un dispositivo de escaneo de seguridad en una instalación. En algunas modalidades, el dispositivo de escaneo de seguridad puede ser una máquina de detección de rayos X en un puerto de entrada u otra instalación segura. La indicación de detección automatizada puede generarse y transmitirse en tiempo real o casi en tiempo real con respecto a cuando la imagen de entrada se recibe en el sistema de procesamiento de imágenes 100.

En algunas modalidades, el sistema de procesamiento de imágenes 100 determina que la anomalía identificada en el bloque 206 es una anomalía de falsa alarma común para un tipo de objeto. En una modalidad ilustrativa, una lista de anomalías de falsas alarmas comunes se almacena en una base de datos. En una modalidad ilustrativa, las anomalías que pueden ser identificadas por el sistema de procesamiento de imágenes pero que son anomalías de falsas alarmas comunes pueden agregarse para generar una lista de anomalías de falsas alarmas comunes para permitir que un(os) algoritmo(s) de aprendizaje automático tenga(n) en cuenta las anomalías de falsas alarmas.

Para implementar el sistema de procesamiento de imágenes descrito en la presente descripción, una modalidad ilustrativa emplea un dispositivo informático que ejecuta LINUX, una o más tarjetas o unidades de procesamiento de gráficos (GPU), una o más imágenes para el entrenamiento y un marco de codificador automático.

La Figura 3 ilustra una topología de red neuronal autocodificadora ilustrativa empleada por el sistema de procesamiento de imágenes, de acuerdo con una modalidad ilustrativa. Un autocodificador es una red neuronal que tiene tres etapas de capas: una etapa de capa de entrada 302, una etapa de capa oculta (codificación) 304 y una etapa de capa de decodificación 306. La red se entrena para reconstruir sus entradas, lo que obliga a la etapa de capa oculta a intentar aprender buenas representaciones de las entradas. Las imágenes se reducen del tamaño original a un vector de características de 20 dimensiones a través de una serie de capas ocultas. La red se entrena al expandir el vector de características al tamaño original y aplicar una función de pérdida para restaurar la imagen original.

El mapeo aprendido por la parte codificadora de la red neuronal autocodificadora es útil para extraer características de los datos. Cada neurona en el codificador tiene un conjunto de pesos asociados con ella, que se ajustarán para responder a una característica visual particular. Las características aprendidas por la red neuronal autocodificadora representan patrones de las imágenes digitales. El conjunto de datos de entrenamiento se usa para entrenar el sistema de procesamiento de imágenes para identificar patrones asociados con el tipo de objeto. Los patrones generados se almacenan y se usan para analizar vectores de características de una o más imágenes de entrada, como se describió anteriormente.

Las Figuras 4A-4C muestra una imagen de salida proporcionada por el sistema de procesamiento de imágenes, de acuerdo con una modalidad ilustrativa. La Figura 4A ilustra imágenes radiográficas 400 de contenedores que contienen tipos de objetos comunes, que incluyen refrigeradores, motocicletas, cerveza, tabaco y tereftalato de polietileno (PET), y un contenedor vacío.

Para cuantificar la disimilitud entre tipos de objetos, el sistema realiza un análisis de imagen mediante el uso de una red neuronal de tipo autocodificador con topología como se muestra en la Figura 4B. El tipo de objeto dentro del contenedor bajo inspección se compara con los contornos de la distribución histórica de un mismo tipo de objeto, que luego se representan gráficamente como se muestra en la Figura 4C.

La Figura 4C muestra vectores de características de alrededor de 120 segmentos de imagen de cuatro tipos de objetos (tabaco, cerveza, refrigeradores y motocicletas) trazados en un gráfico, así como también segmentos de imagen para un contenedor vacío y un contenedor de PET. El agrupamiento de puntos del mismo tipo de objeto 430A, 430B, 430C, 430D, 430E y 430F indica que el tipo de objeto puede distinguirse en base a las características de la imagen.

La verificación del contenido del contenedor puede lograrse mediante la comparación de datos del manifiesto y las imágenes radiográficas. En algunas modalidades, el sistema analiza el manifiesto y verifica automáticamente que el patrón de imagen coincida con los objetos enumerados en el manifiesto. En otras modalidades, los operadores en los puntos de control de seguridad pueden recibir imágenes radiográficas de contenedores y/o un manifiesto con información de contenido para cada contenedor. En tal modalidad, el operador verifica que el patrón de imagen coincida con los objetos enumerados en el manifiesto.

La Figura 5 ilustra un diagrama de red que representa un sistema 500 para implementar el sistema de procesamiento de imágenes, de acuerdo con una modalidad ilustrativa. El sistema 500 puede incluir una red 505, múltiples dispositivos, por ejemplo, el dispositivo 510, el dispositivo de escaneo 520, el servidor 530 y una(s) base(s) de datos 540. Cada uno de los dispositivos 510, 520, servidor 530 y base(s) de datos 540 está en comunicación con la red 505.

En una modalidad de ejemplo, una o más porciones de la red 505 pueden ser una red ad hoc, una intranet, una extranet, una red privada virtual (VPN), una red de área local (LAN), una red de área local inalámbrica (WLAN), una red de área amplia (WAN), una red de área amplia inalámbrica (WWAN), una red de área metropolitana (MAN), una porción de Internet, una porción de la Red telefónica pública conmutada (PSTN), una red de telefonía celular, una red inalámbrica, una red Wi-Fi, una red WiMax, cualquier otro tipo de red o una combinación de dos o más de tales redes.

El dispositivo 510 puede incluir, pero no se limita a, estaciones de trabajo, ordenadores, ordenadores de propósito general, dispositivos de Internet, dispositivos portátiles, dispositivos inalámbricos, dispositivos portátiles, ordenadores portátiles, teléfonos celulares o móviles, asistentes digitales portátiles (PDA), teléfonos inteligentes, tabletas, ultraportátiles, netbooks, ordenadores portátiles, ordenadores de escritorio, sistemas multiprocesadores, electrónicos de consumo basados en microprocesadores, PC de red, miniordenadores y similares. El dispositivo 510 puede conectarse a la red 505 a través de una conexión cableada o inalámbrica.

El dispositivo de escaneo 520 incluye una máquina o sistema radiográfico para escanear contenedores, y puede producir imágenes radiográficas renderizadas de contenedores escaneados en un dispositivo de visualización acoplado al dispositivo de escaneo 520. En una modalidad de ejemplo, el dispositivo de escaneo 520 es un sistema de detección de seguridad en un punto de control. El dispositivo de escaneo 520 puede usarse para escanear contenedores de envío con fines de seguridad. En una modalidad ilustrativa, las imágenes producidas por el dispositivo de escaneo 520 se usan como el conjunto de datos para entrenar el(los) algoritmo(s) de aprendizaje automático como se describe en la presente descripción. El dispositivo de escaneo 520 produce la imagen de entrada para el sistema de procesamiento de imágenes 100. Después de que la imagen de entrada se procesa, la imagen de salida puede mostrarse en el dispositivo de visualización acoplado al dispositivo de escaneo 520, donde la imagen de salida puede incluir una etiqueta para una anomalía y una indicación de la ubicación de la anomalía dentro de la imagen.

Como un módulo adicional, el sistema de procesamiento de imágenes descrito en la presente descripción puede cargarse como un módulo de software en un dispositivo de punto de control de seguridad existente o en un servidor existente en red con uno o más dispositivos. El sistema de procesamiento de imágenes genera una alarma y alerta al operador del dispositivo de control de seguridad sobre anomalías detectadas, además de cualquier otra tecnología de detección que pueda instalarse en esos dispositivos o servidores.

Un experto en la técnica puede apreciar que la capacidad de complemento puede añadirse a una variedad de dispositivos de imagen radiográfica. De esta manera, las alertas generadas por el complemento del sistema de procesamiento de imágenes descrito en la presente descripción pueden mostrarse en la pantalla junto con las alarmas generadas por otro software de detección.

En una modalidad ilustrativa, los dispositivos 510, 520 pueden realizar una o más de las funcionalidades del sistema de procesamiento de imágenes 100 descrito en la presente descripción. El dispositivo 510, 520 puede incluir uno o más componentes del dispositivo informático 500 de la Figura 5. El dispositivo 510, 520 puede usarse para entrenar el(los) algoritmo(s) de aprendizaje automático, y después usar el algoritmo entrenado en imágenes de entrada para identificar la presencia de una anomalía. Por ejemplo, el dispositivo 510, 520 puede almacenar y ejecutar la primera red neuronal 550 para realizar el análisis de imágenes radiográficas y la segunda red neuronal 560 para realizar el análisis del manifiesto de carga para un contenedor de envío.

En una modalidad ilustrativa, el sistema de procesamiento de imágenes 100 puede incluirse en el servidor 530, y el servidor 530 realiza una o más de las funcionalidades del sistema de procesamiento de imágenes 100 descritas en la presente descripción. En algunas modalidades, los dispositivos 510, 520 pueden realizar algunas de las funcionalidades, y el servidor 530 realiza las otras funcionalidades descritas en la presente descripción.

Cada una de las bases de datos 540 y el servidor 530 se conecta a la red 505 a través de una conexión por cable o inalámbrica. El servidor 530 incluye uno o más ordenadores o procesadores configurados para comunicarse con los dispositivos 510, 520 a través de la red 505. El servidor 530 puede incluir uno o más componentes del dispositivo 600 de la Figura 6. El servidor 530 aloja una o más aplicaciones o sitios web, que incluyen el sistema de procesamiento de imágenes descrito en la presente descripción, al que acceden los dispositivos 510, 520 y/o facilita el acceso al contenido de la(s) base(s) de datos 540. La(s) base(s) de datos 540 incluye(n) uno o más dispositivos de almacenamiento para almacenar datos y/o instrucciones (o código) para su uso por el servidor 530, y/o los dispositivos 510, 520. La(s) base(s) de datos 540 y el servidor 530 pueden ubicarse en una o más ubicaciones geográficamente distribuidas entre sí o desde los dispositivos 510, 520. Alternativamente, la(s) base(s) de datos 540 puede(n) incluirse dentro del servidor 530.

El sistema 500 incluye una primera red neuronal 550 y una segunda red neuronal 560. La primera red neuronal 550 se usa para extraer vectores de características de imágenes radiográficas, como se describe en la presente

descripción. La segunda red neuronal 560 se usa para el análisis del texto del manifiesto de carga, como se describe en la presente descripción. En algunas modalidades, el dispositivo 510 y/o el servidor 520 utilizan la primera red neuronal 550 y la segunda red neuronal 560 para procesar imágenes y manifiestos de carga para verificar el contenido de los contenedores y/o identificar anomalías en las imágenes y los manifiestos de carga, como se describe en la

5

La Figura 6 es un diagrama de bloques de un dispositivo informático ilustrativo 600 que puede usarse para realizar una o más etapas de los métodos proporcionados por las modalidades ilustrativas. Por ejemplo, el dispositivo informático 600 puede ser, pero no se limita a, el dispositivo 510, 520 y el servidor 530 como se describe en la Figura 5. El dispositivo informático 600 incluye uno o más medios legibles por ordenador no transitorios para almacenar una o más instrucciones o software ejecutables por ordenador para implementar modalidades ilustrativas. Los medios legibles por ordenador no transitorios pueden incluir, pero no se limitan a, uno o más tipos de memoria de hardware, medios tangibles no transitorios (por ejemplo, uno o más discos de almacenamiento magnético, uno o más discos ópticos, una o más unidades flash USB), y similares. Por ejemplo, la memoria 606 incluida en el dispositivo informático 600 puede almacenar instrucciones o software legibles y ejecutables por ordenador para implementar modalidades ilustrativas. El dispositivo informático 600 también incluye el procesador 602 y el núcleo asociado 604, y opcionalmente, uno o más procesadores adicionales 602' y núcleos asociados 604' (por ejemplo, en el caso de sistemas informáticos que tienen múltiples procesadores/núcleos), para ejecutar instrucciones o software legibles por ordenador y ejecutables por ordenador almacenados en la memoria 606 y otros programas para controlar el hardware del sistema. El procesador 602 y el o los procesadores 602' pueden ser cada uno un procesador de un solo núcleo o un procesador de múltiples núcleos (604 y 604'). El dispositivo informático 600 también incluye una unidad de procesamiento de gráficos (GPU) 605. En algunas modalidades, el dispositivo informático 600 incluye múltiples GPU.

10

15

20

La virtualización puede emplearse en el dispositivo informático 600 de manera que la infraestructura y los recursos en el dispositivo informático puedan compartirse dinámicamente. Puede proporcionarse una máquina virtual 614 para manejar un proceso que se ejecuta en múltiples procesadores de manera que el proceso parezca usar solo un recurso informático en lugar de múltiples recursos informáticos. También pueden usarse múltiples máquinas virtuales con un procesador.

25

La memoria 606 puede incluir una memoria de sistema informático o memoria de acceso aleatorio, tal como DRAM, SRAM, EDO RAM y similares. La memoria 606 también puede incluir otros tipos de memoria, o sus combinaciones. Un usuario puede interactuar con el dispositivo informático 600 a través de un dispositivo de visualización visual 618, tal como una pantalla táctil o un monitor de ordenador, que puede mostrar una o más interfaces de usuario 616. El dispositivo de visualización 618 también puede mostrar otros aspectos, elementos y/o información o datos asociados con modalidades ilustrativas. El dispositivo informático 600 puede incluir otros dispositivos de E/S para recibir entradas de un usuario, por ejemplo, un teclado o cualquier interfaz táctil multipunto adecuada 608, un dispositivo de puntero 610 (por ejemplo, un bolígrafo, un lápiz óptico, un ratón o una almohadilla de seguimiento). El teclado 608 y el dispositivo señalador 610 pueden acoplarse al dispositivo de visualización 618. El dispositivo informático 600 puede incluir otros periféricos de E/S convencionales adecuados.

30

35

El dispositivo informático 600 también puede incluir uno o más dispositivos de almacenamiento 624, tales como un disco duro, CD-ROM u otro medio legible por ordenador, para almacenar datos e instrucciones y/o software legibles por ordenador, tales como uno o más módulos del sistema 100 que se muestran en la Figura 1 que implementa modalidades ilustrativas del sistema de notificación como se describe en la presente descripción, o porciones de estas, que pueden ejecutarse para generar la interfaz de usuario 616 en la pantalla 618. El dispositivo de almacenamiento ilustrativo 624 también puede almacenar una o más bases de datos para almacenar cualquier información adecuada requerida para implementar las modalidades ilustrativas. Las bases de datos pueden actualizarse por un usuario o automáticamente en cualquier momento adecuado para agregar, eliminar o actualizar uno o más objetos en las bases de datos. El dispositivo de almacenamiento ilustrativo 624 puede almacenar algunos o todos los datos del sistema de procesamiento de imágenes 100, que incluyen los datos de entrenamiento 100A, la primera red neuronal 100B, la segunda red neuronal 100C y/o los algoritmos 110D (tales como, pero sin limitarse a, un algoritmo de verificación de manifiesto, un algoritmo de verificación de contenedor vacío, un algoritmo de detección de tipo de carga, un algoritmo de detección de anomalías y/o un algoritmo de monitoreo de calidad de datos).

40

45

50

El dispositivo informático 600 puede incluir una interfaz de red 612 configurada para interactuar a través de uno o más dispositivos de red 622 con una o más redes, por ejemplo, Red de área local (LAN), Red de área amplia (WAN) o Internet a través de una variedad de conexiones que incluyen, pero sin limitarse a, líneas telefónicas estándar, enlaces LAN o WAN (por ejemplo, 802.11, T1, T3, 56 kb, X.25), conexiones de banda ancha (por ejemplo, ISDN, Frame Relay, ATM), conexiones inalámbricas, red de área de control (CAN), o alguna combinación de cualquiera o todas las anteriores. La interfaz de red 612 puede incluir un adaptador de red integrado, una tarjeta de interfaz de red, una tarjeta de red PCMCIA, un adaptador de red de bus de tarjeta, un adaptador de red inalámbrica, un adaptador de red USB, un módem o cualquier otro dispositivo adecuado para la interfaz del dispositivo informático 600 a cualquier tipo de red capaz de comunicación y realizar las operaciones descritas en la presente descripción. Además, el dispositivo informático 600 puede ser cualquier sistema informático, tal como una estación de trabajo, ordenador de escritorio, servidor, ordenador portátil, ordenador de mano, tableta (por ejemplo, el iPad® tableta), dispositivo informático o de comunicación móvil (por ejemplo, el iPhone® dispositivo de comunicación), u otra forma de dispositivo informático o

55

60

65

de telecomunicaciones que sea capaz de comunicarse y que tenga suficiente potencia de procesador y capacidad de memoria para realizar las operaciones descritas en la presente descripción.

5 El dispositivo informático 600 puede ejecutar cualquier sistema operativo 616, tal como cualquiera de las versiones de Microsoft® Ventanas® sistemas operativos, sistemas operativos móviles, Android e iOS, las diferentes versiones de los sistemas operativos Unix y Linux, cualquier versión de MacOS® para ordenadores Macintosh, cualquier sistema operativo integrado, cualquier sistema operativo en tiempo real, cualquier sistema operativo de código abierto, cualquier sistema operativo propietario, cualquier sistema operativo para dispositivos informáticos móviles, o cualquier otro sistema operativo capaz de ejecutarse en el dispositivo informático y realizar las operaciones descritas en la presente descripción. En modalidades ilustrativas, el sistema operativo 616 puede ejecutarse en modo nativo o modo emulado. En una modalidad ilustrativa, el sistema operativo 616 puede ejecutarse en una o más instancias de máquina en la nube.

15 La Figura 7 ilustra una arquitectura de red neuronal ilustrativa para el análisis de texto manifiesto, de acuerdo con una modalidad ilustrativa. Las neuronas de entrada son segmentos de palabras (n-gramas) que se encuentran en los datos manifiestos, incluidos las etiquetas de tipo de carga. El propósito del entrenamiento de la red neuronal es encontrar la correlación entre los segmentos de palabras que ocurren en el mismo contexto de manera que las palabras relacionadas tengan vectores de características similares. El entrenamiento usa tanto la parte codificadora como la decodificadora de la red, mientras que la evaluación del manifiesto usa solo la parte codificadora que calcula el vector de características. La carga se clasifica seleccionando una etiqueta de carga que tiene un vector de características cerrado con el promedio del texto del manifiesto.

20 La Figura 8 ilustra una implementación ilustrativa de un algoritmo de verificación de manifiesto (MV) para ayudar a un operador en una decisión de inspección, de acuerdo con una modalidad ilustrativa. El operador ve una imagen bajo inspección 802 y/o texto sin procesar del manifiesto. Los resultados 804 del algoritmo MV se muestran al operador. Como se muestra en los resultados 804, el MV interpreta el manifiesto y asigna una etiqueta 806 que explica el contenido de la carga al operador. El MV también muestra imágenes 808 de exploraciones anteriores con el mismo contenido de carga. El MV muestra un nivel de confianza 810 de que la imagen coincide con el manifiesto. Los resultados 804 del algoritmo MV se muestran típicamente a través de una interfaz de usuario.

30 La Figura 9 ilustra una curva de Características del Operador-Receptor (ROC) 902 ilustrativa que relaciona la eficiencia de la verificación de manifiestos con la interdicción de la carga documentada incorrectamente de acuerdo con una modalidad ilustrativa. La eficiencia de la verificación de manifiestos se define como la fracción de la carga documentada correctamente que se libera por el algoritmo. La tasa de interdicción es la fracción de carga documentada incorrectamente que se señala mediante el algoritmo. Cada curva ROC pertenece a una categoría de carga y el gráfico muestra aproximadamente 200 categorías. En la implementación ilustrativa, todas las categorías de carga tienen al menos 70 % de tasa de interdicción al 80 % de la tasa de liberación de manifiesto.

40 La Figura 10 ilustra una implementación de un algoritmo de validación de contenedor vacío (ECV) que marcó una bolsa de lona llena de moneda en un contenedor declarado vacío, de acuerdo con una modalidad ilustrativa. Una región sospechosa 1002 se marca en la imagen para la atención del operador. Se añade una fotografía 1004 a la figura para mostrar el objetivo de prueba.

45 La Figura 11 ilustra segmentos de contenedor 1102 que se usan para la detección de anomalías, de acuerdo con una modalidad ilustrativa. Cada segmento 1102 (como se ilustra a través del uso de una superposición de cuadrícula para explicar la segmentación) se evalúa con una red neuronal autocodificadora que proporciona un vector de características, de acuerdo con una modalidad ilustrativa. El resultado es identificar segmentos 1102 que son significativamente diferentes del resto de los segmentos. Como se representa en la Figura 11 se han identificado algunos segmentos 1104 que indican una anomalía.

50 La Figura 12 ilustra los resultados de una implementación ilustrativa de un algoritmo de detección de anomalías, de acuerdo con una modalidad ilustrativa. La red neuronal genera un vector de características para cada segmento, y el módulo de salida genera el mapa de calor de chi cuadrado (mediante la comparación de vectores de características). En algunas modalidades, los colores indican los valores de chi cuadrado del segmento bajo inspección de los otros segmentos. El chi-cuadrado se calcula como la distancia al cuadrado entre el vector de características del segmento y el promedio de vectores de características de otros segmentos, dividido por la desviación estándar al cuadrado de vectores de características de otros segmentos. Este chi cuadrado se normaliza al grado de libertad, es decir, el número de características menos uno. Los resultados indican una anomalía 1204 detectada en ciertos segmentos del contenedor de envío (como se muestra en la Figura 11). Por ejemplo, la anomalía puede indicar un objeto en un contenedor que se supone que está vacío, o un objeto de un tipo diferente al enumerado en el manifiesto de carga.

65 La Figura 13 es un diagrama de flujo que ilustra un método ilustrativo para validar manifiestos de carga empleados por el sistema de procesamiento de imágenes, de acuerdo con una modalidad ilustrativa. En la etapa 1302, un dispositivo informático recibe una imagen radiográfica renderizada de un escáner que incluye un contenedor de envío en la imagen. En la etapa 1304, se extrae un vector de características de la imagen radiográfica del contenedor de envío escaneado mediante el uso de una red neuronal autocodificadora. En la etapa 1306, el sistema de

procesamiento de imágenes asigna una probabilidad estadística de que el contenedor coincida con un objeto enumerado en un manifiesto de carga asociado para el contenedor de envío escaneado. Como se analizó anteriormente, en la etapa 1308, la probabilidad estadística se determina además mediante la realización de un análisis adicional de palabras en manifiestos de carga mediante el uso de una segunda red neuronal artificial. En la etapa 1310, el sistema de procesamiento de imágenes genera entonces una indicación de detección automatizada relacionada con el contenedor de envío escaneado en base a la probabilidad estadística asignada. La indicación de detección puede adoptar varias formas tales como, pero sin limitarse a, generar pantallas de advertencia o alarmas audibles.

La Figura 14 es un diagrama de flujo que ilustra un método ilustrativo empleado por el sistema de procesamiento de imágenes para confirmar que los contenedores de envío vacíos designados están de hecho vacíos, de acuerdo con una modalidad ilustrativa. En la etapa 1402, un dispositivo informático recibe una imagen radiográfica renderizada de un contenedor de envío. En la etapa 1404, se extrae un vector de características de la imagen mediante el uso de una red neuronal autocodificadora. En la etapa 1406, el sistema de procesamiento de imágenes asigna una probabilidad estadística de la vacuidad del contenedor de envío escaneado en base a la comparación del vector de características extraído con una distribución histórica de vectores de características extraídos de imágenes radiográficas asociadas con contenedores de envío vacíos anteriores.

En la descripción de las modalidades ilustrativas, se usa terminología específica en aras de la claridad. Para fines de descripción, cada término específico pretende incluir al menos todos los equivalentes técnicos y funcionales que operan de una manera similar para lograr un propósito similar. Adicionalmente, en algunos casos donde una modalidad ilustrativa particular incluye múltiples elementos del sistema, componentes del dispositivo, o etapas del método, esos elementos, componentes, o etapas pueden reemplazarse con un solo elemento, componente, o etapa. Igualmente, un solo elemento, componente o etapa puede reemplazarse con múltiples elementos, componentes o etapas que sirven para el mismo propósito. Además, aunque las modalidades ilustrativas se han mostrado y descrito con referencias a modalidades particulares de las mismas, los expertos en la técnica entenderán que pueden realizarse diversas sustituciones y alteraciones en la forma y el detalle en la misma sin apartarse del alcance de la presente descripción. Aún más, otras modalidades, funciones y ventajas también están dentro del alcance de la presente descripción.

REIVINDICACIONES

1. Un método implementado en un dispositivo informático para validar un manifiesto de carga asociado con un contenedor de envío, el método que comprende:
 - 5 recibir, en un dispositivo informático (510), una imagen radiográfica renderizada de un contenedor de envío escaneado desde un escáner (520) configurado para escanear el contenedor de envío y renderizar la imagen radiográfica;
 - extraer, con una red neuronal autocodificadora (550), un vector de características de la imagen radiográfica;
 - 10 determinar una probabilidad estadística de que un objeto en el contenedor de envío escaneado coincida con un objeto enumerado en un manifiesto de carga asociado con el contenedor de envío escaneado en base al menos en parte a:
 - una comparación del vector de características extraído contra una distribución histórica de vectores de características anteriores de imágenes radiográficas de contenedores de envío anteriores asociados con manifiestos de carga que contienen un objeto similar; y
 - 15 generar una indicación de detección automatizada relacionada con el contenedor de envío escaneado en base a la probabilidad estadística determinada, la indicación de detección automatizada:
 - proporcionar un indicador gráfico de un grado de consistencia del contenido del contenedor escaneado con el manifiesto de carga asociado, y/o
 - proporcionar una visualización de una clasificación de imágenes radiográficas, y/o
 - 20 ser una indicación gráfica o una indicación audible que alerta a un usuario de que se detecta una anomalía en la imagen radiográfica, y/o ser una etiqueta de texto que identifica la anomalía, y/o
 - ser una forma de caja de color que encierra la anomalía, y/o
 - indicar si la imagen radiográfica es consistente con un contenedor vacío;
 - 25 caracterizado porque la probabilidad estadística se determina además en base a al menos en parte al procesamiento de lenguaje natural del manifiesto de carga por una segunda red neuronal artificial.
2. El método de la reivindicación 1 que comprende,
 - 30 entrenar la red neuronal autocodificadora con un conjunto de datos de entrenamiento de imágenes radiográficas para generar al menos un vector de características anterior que representa matemáticamente características numéricas o simbólicas del objeto en el contenedor de envío escaneado, el conjunto de datos de entrenamiento que incluye un primer conjunto de imágenes radiográficas anteriores de uno o más contenedores de envío anteriores que contienen objetos similares.
3. El método de la reivindicación 1, en donde la segunda red neuronal artificial es una red neuronal recurrente no supervisada entrenada en una base de datos histórica de manifiestos de carga de contenedores de envío anteriores.
4. El método de la reivindicación 3, en donde la segunda red neuronal artificial es una red neuronal de tipo palabra a vector.
5. El método de la reivindicación 3, en donde la segunda red neuronal artificial hace uso de incrustaciones de palabras preentrenadas de manifiestos de carga de contenedores de envío anteriores históricos para analizar el manifiesto de carga.
6. El método de la reivindicación 1, en donde la red neuronal autocodificadora es una red neuronal no supervisada.
7. El método de la reivindicación 1, que comprende, además: mostrar una asignación categórica de la validación o el rechazo del manifiesto de carga en base a la probabilidad estadística.
8. El método de la reivindicación 1, en donde varias imágenes de contenedores de envío anteriores asociados con manifiestos de carga similares a los asociados con el contenedor de envío escaneado se muestran en tiempo real, y/o varios manifiestos anteriores similares a los asociados con el contenedor de envío escaneado se muestran en tiempo real.
9. Un sistema para validar un manifiesto de carga asociado con un contenedor de envío, el sistema que comprende:
 - 55 un escáner (520) configurado para escanear un contenedor de envío y producir al menos una imagen radiográfica;
 - un dispositivo informático (510) equipado con uno o más procesadores y acoplado comunicativamente al escáner, el dispositivo informático configurado para:
 - 60 recibir una imagen radiográfica renderizada de un contenedor de envío escaneado desde el escáner,
 - extraer, con una red neuronal autocodificadora (550), un vector de características de la imagen radiográfica,
 - determinar una probabilidad estadística de que un objeto en el contenedor de envío escaneado coincida con un objeto enumerado en un manifiesto de carga asociado con el contenedor de envío escaneado en base al menos en parte a:
 - 65 una comparación del vector de características extraído con una distribución histórica de vectores de características anteriores de imágenes radiográficas de contenedores de envío anteriores asociados con

manifiestos de carga que contienen un objeto similar, y
generar una indicación de detección automatizada relacionada con el contenedor de envío escaneado en base a la probabilidad estadística determinada, la indicación de detección automatizada:

- 5 proporcionar un indicador gráfico de un grado de consistencia del contenido del contenedor escaneado con el manifiesto de carga asociado, y/o
- proporcionar una visualización de una clasificación de imágenes radiográficas, y/o
- ser una indicación gráfica o una indicación audible que alerta a un usuario de que se detecta una anomalía en la imagen radiográfica, y/o
- 10 que es una etiqueta de texto que identifica la anomalía, y/o
- ser una forma de caja de color que encierra la anomalía, y/o
- indicar si la imagen radiográfica es consistente con un contenedor vacío; y
- un mecanismo de salida configurado para emitir la indicación de detección automatizada mediante la visualización de gráficos o la generación de audio;
- 15 caracterizado porque la probabilidad estadística se determina además en base a al menos en parte al procesamiento de lenguaje natural del manifiesto de carga por una segunda red neuronal artificial.

10. El sistema de la reivindicación 9, en donde la red neuronal autocodificadora se entrena con un conjunto de datos de entrenamiento de imágenes radiográficas para generar al menos un vector de características anterior que representa matemáticamente características numéricas o simbólicas del objeto en el contenedor de envío escaneado, el conjunto de datos de entrenamiento que incluye un primer conjunto de imágenes radiográficas anteriores de uno o más contenedores de envío anteriores que contienen objetos similares.

11. El sistema de la reivindicación 9, en donde la segunda red neuronal artificial es una red neuronal recurrente no supervisada entrenada en una base de datos histórica de manifiestos de carga de contenedores de envío anteriores.

12. El sistema de la reivindicación 11, en donde la segunda red neuronal artificial es una red neuronal de tipo palabra a vector.

13. El sistema de la reivindicación 11, en donde la segunda red neuronal artificial hace uso de incrustaciones de palabras preentrenadas de manifiestos de carga de contenedores de envío anteriores históricos para analizar el manifiesto de carga.

14. El sistema de la reivindicación 9, en donde la red neuronal autocodificadora es una red neuronal no supervisada.

15. El sistema de la reivindicación 9, en donde el dispositivo informático se configura además para mostrar:
una asignación categórica de la validación o el rechazo del manifiesto de carga en base a la probabilidad estadística, y/o
40 varias imágenes de contenedores de envío anteriores asociados con manifiestos de carga similares a los asociados con el contenedor de envío escaneado en tiempo real, y/o
una pluralidad de manifiestos anteriores similares a los asociados con el contenedor de envío escaneado en tiempo real, y/o
una asignación categórica de objetos enumerados en el manifiesto de carga asociado.

16. Un medio legible por ordenador no transitorio que almacena instrucciones ejecutables por un procesador para validar un manifiesto de carga asociado con un contenedor de envío, en donde la ejecución de las instrucciones hace que un dispositivo informático (510) ejecute el método de cualquiera de las reivindicaciones 1 a 8.

50

55

60

65

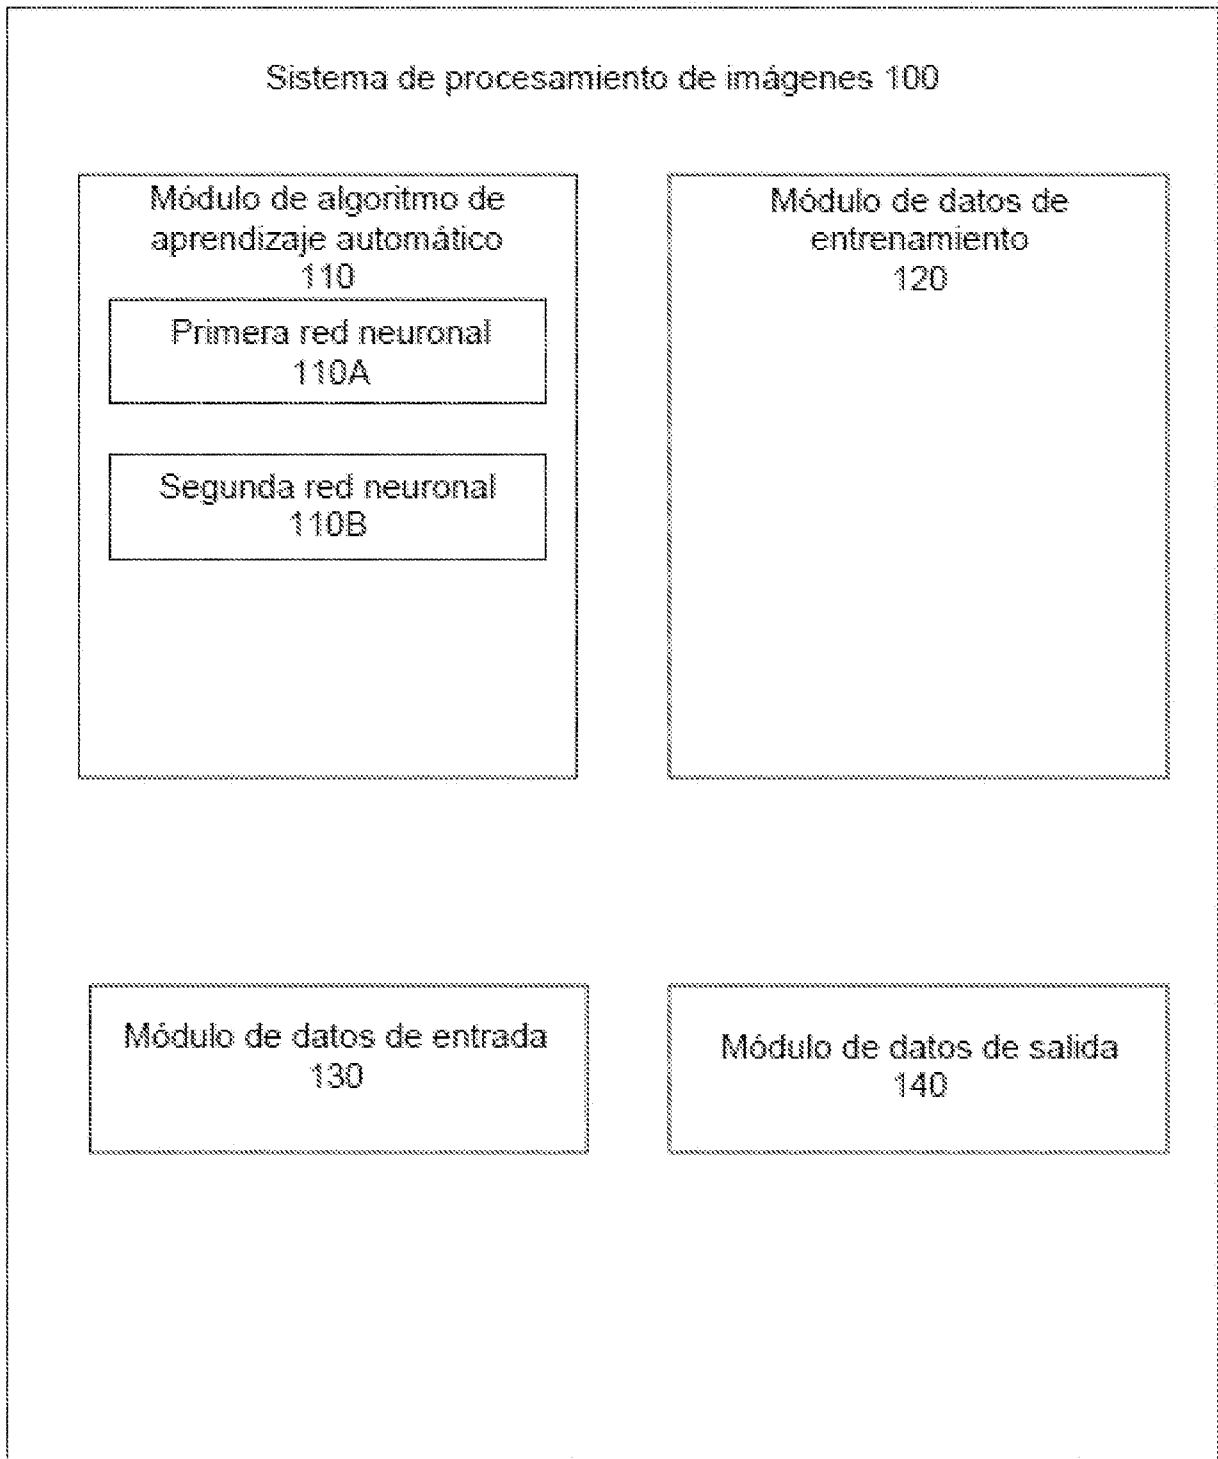


Figura 1

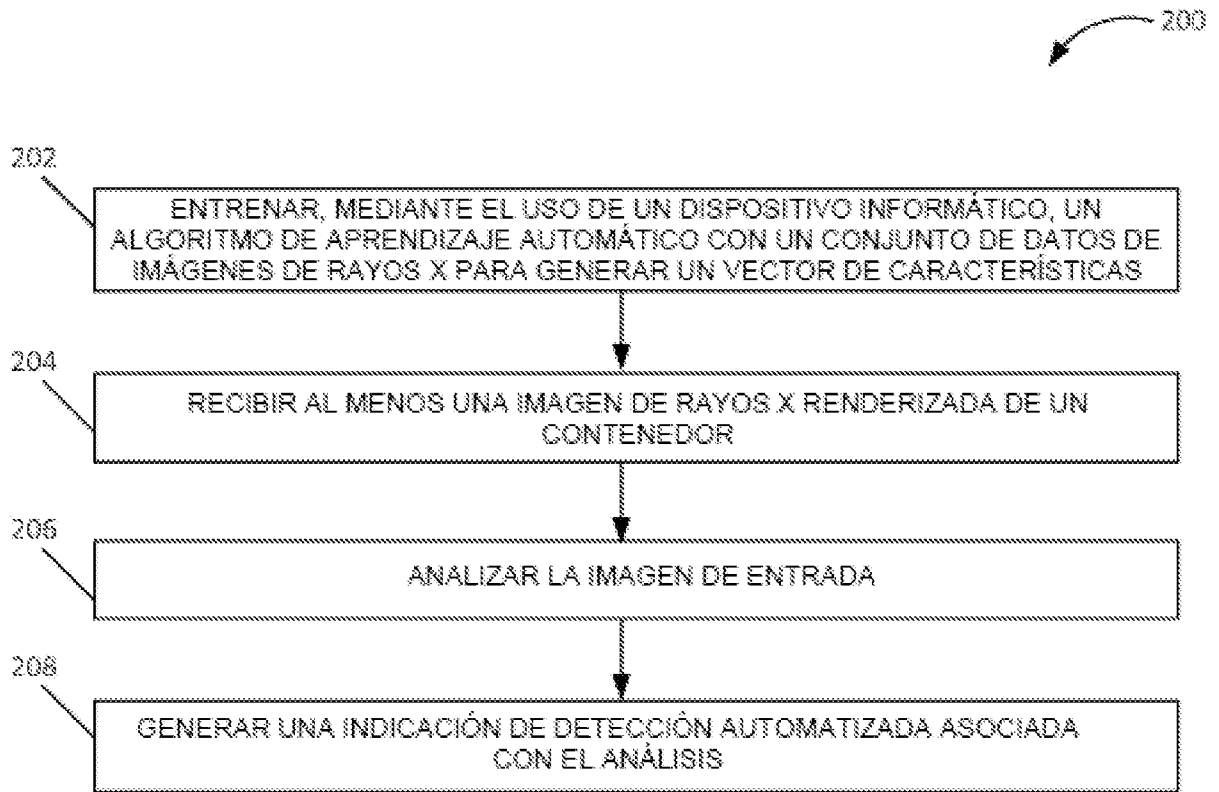


Figura 2




Figura 3

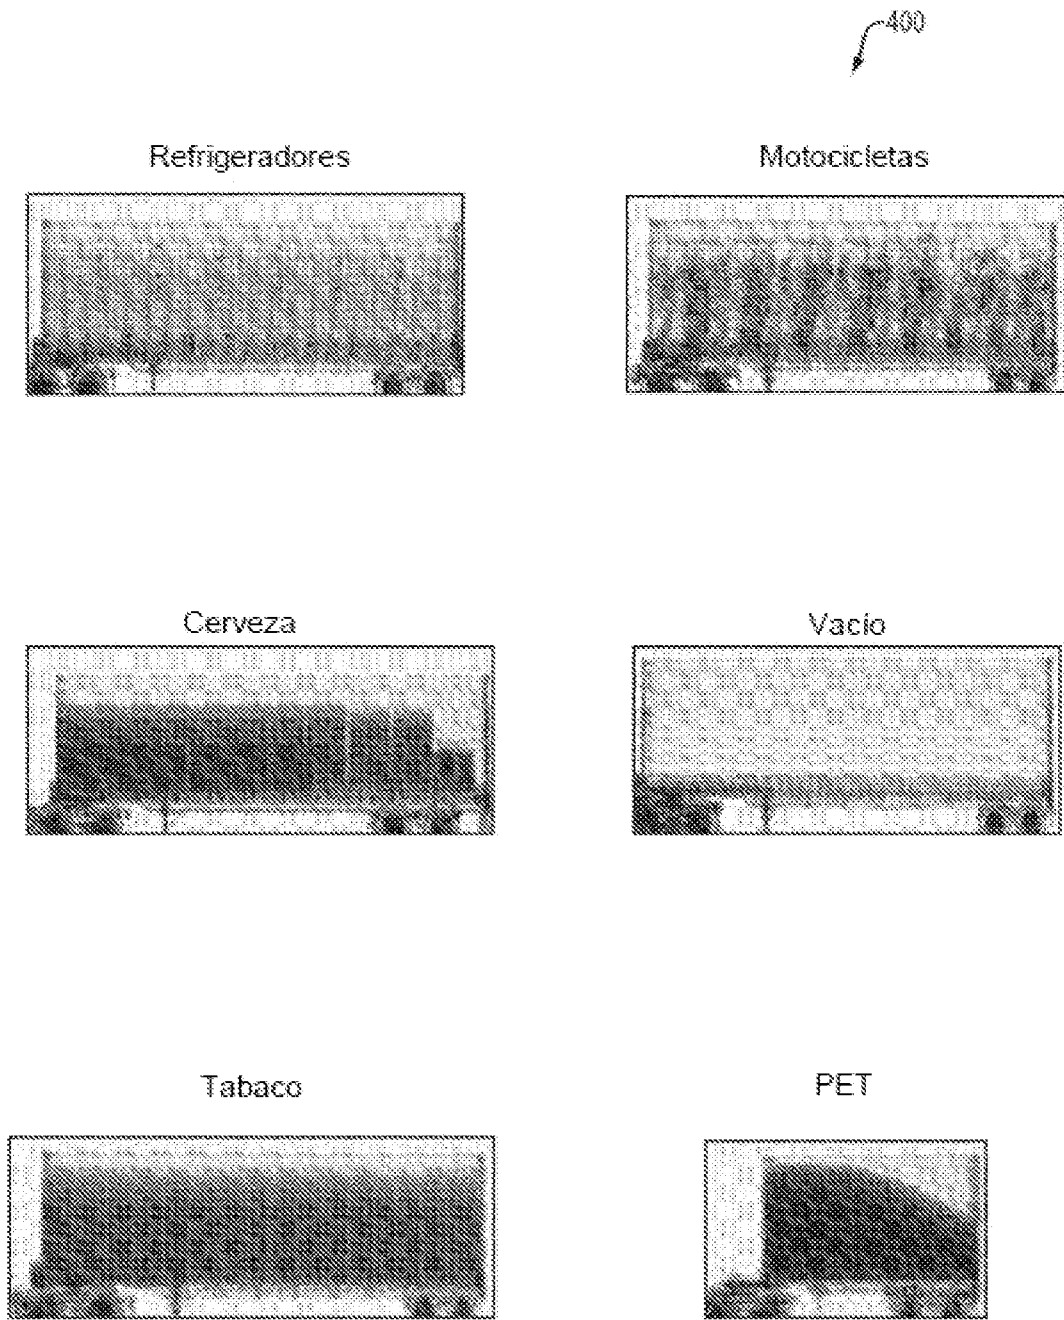


Figura 4A




Figura 4B

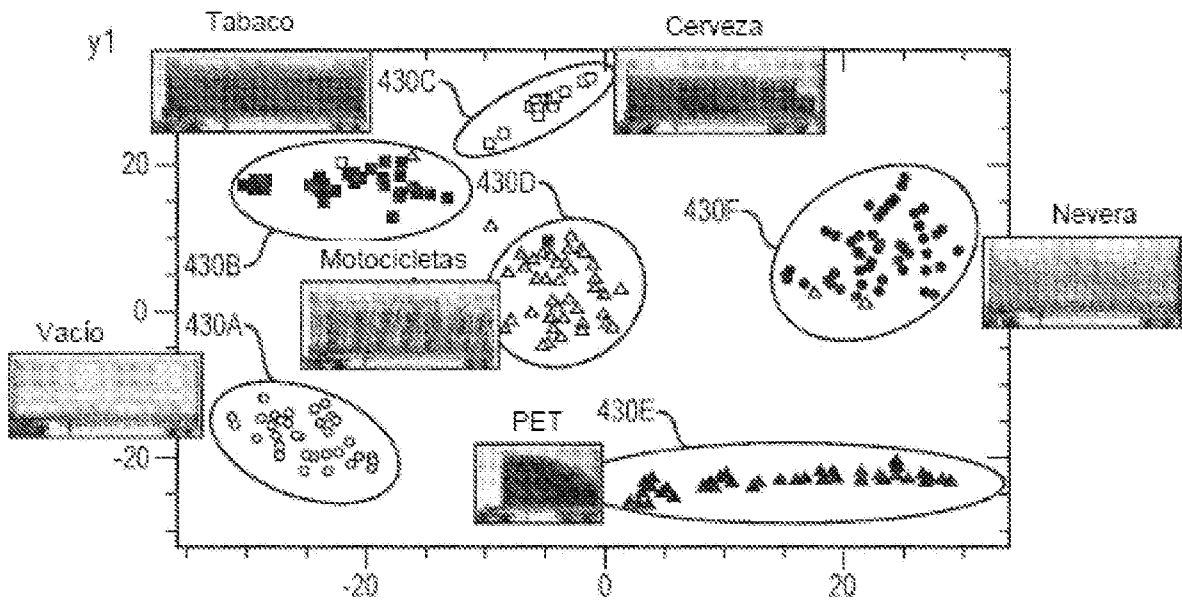


Figura 4C




Figura 5




Figura 6

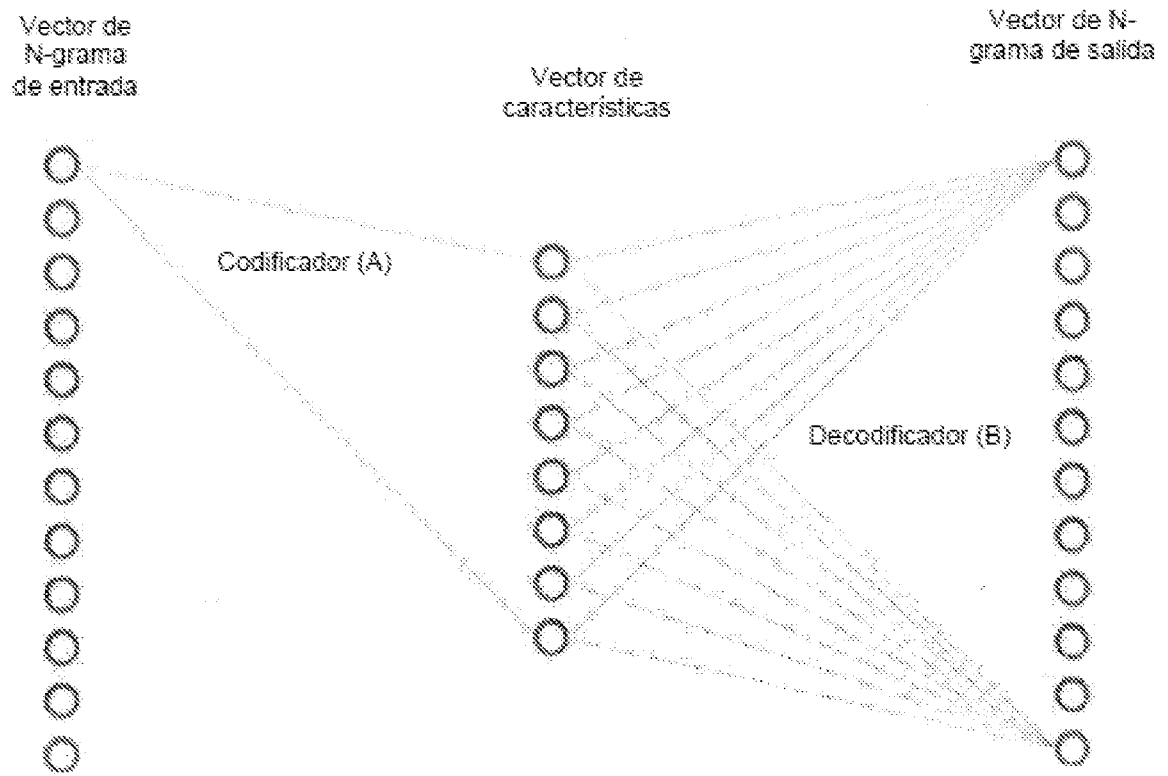


Figura 7




Figura 8




Figura 9




Figura 10




Figura 11




Figure 12

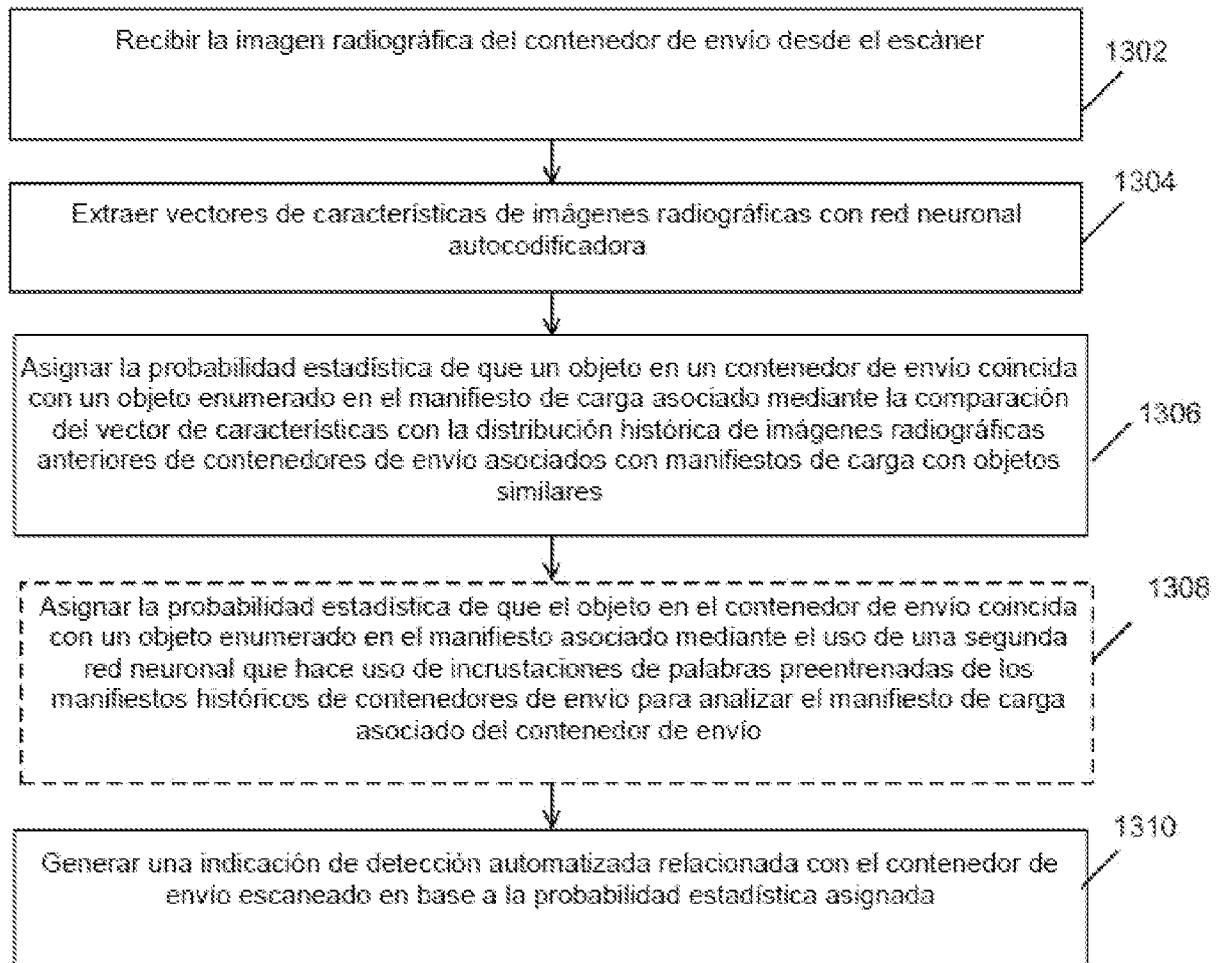


Figura 13

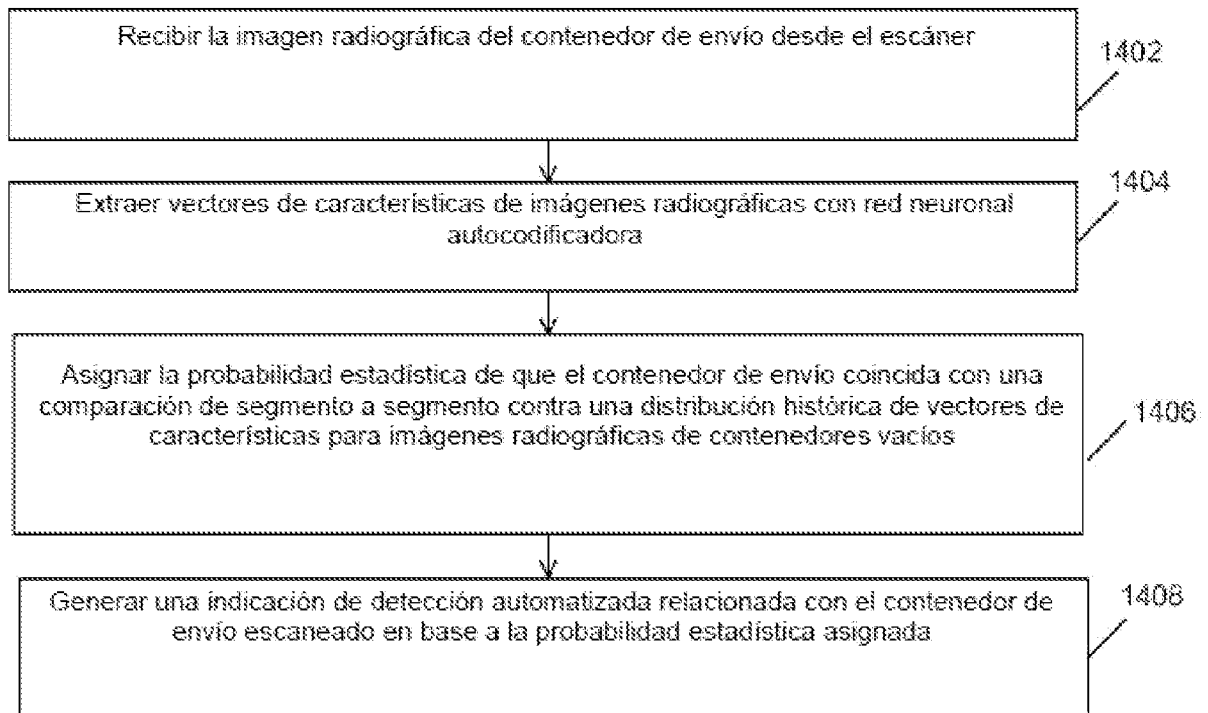


Figura 14