

19



OFICINA ESPAÑOLA DE
PATENTES Y MARCAS

ESPAÑA



11 Número de publicación: **2 906 349**

51 Int. Cl.:

G06T 5/00 (2006.01)

G06T 5/20 (2006.01)

G06T 5/50 (2006.01)

12

TRADUCCIÓN DE PATENTE EUROPEA

T3

86 Fecha de presentación y número de la solicitud internacional: **20.03.2018** **PCT/US2018/023383**

87 Fecha y número de publicación internacional: **04.10.2018** **WO18183044**

96 Fecha de presentación y número de la solicitud europea: **20.03.2018** **E 18774771 (2)**

97 Fecha y número de publicación de la concesión europea: **17.11.2021** **EP 3600026**

54 Título: **Mejora de la calidad de imágenes médicas usando multicontraste y aprendizaje profundo**

30 Prioridad:

31.03.2017 US 201715475760

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

18.04.2022

73 Titular/es:

**THE BOARD OF TRUSTEES OF THE LELAND
STANFORD JUNIOR UNIVERSITY (100.0%)
Office of the General Counsel Building 170, Third
Floor, Main Quad P.O. Box 20386
Stanford, CA 94305-2038, US**

72 Inventor/es:

**ZAHARCHUK, GREG;
GONG, ENHAO y
PAULY, JOHN, M.**

74 Agente/Representante:

PONS ARIÑO, Ángel

ES 2 906 349 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

Mejora de la calidad de imágenes médicas usando multicontraste y aprendizaje profundo

CAMPO DE LA INVENCIÓN

La invención se refiere a la obtención de imágenes médicas. Más específicamente, la invención se refiere a mejorar la calidad de imágenes médicas usando obtención de imágenes multicontraste, filtros multilaterales y procedimientos de aprendizaje profundo.

ANTECEDENTES DE LA INVENCIÓN

Con la eliminación del ruido de las imágenes médicas, se han propuesto múltiples procedimientos que incluyen el filtrado gaussiano, filtrado de ondículas y algoritmos de medios no locales (NLM), donde la experimentación ha demostrado que el NLM (posiblemente combinando con las ondículas) es el procedimiento superior. Sin embargo, todos estos procedimientos aún comparten algunas desventajas, tales como la dependencia del ajuste de parámetros para diferentes imágenes. En un aspecto, un procedimiento propuesto usó la redundancia y las relaciones de las imágenes multicontraste como base para eliminar el ruido de la imagen. Se han usado trabajos relacionados para combinar un par de imágenes borrosas y con ruido para cámaras y sensores CMOS. Una implementación adicional usó la representación grupo-dispersión para eliminar el ruido de la imagen, que también usó la información multicontraste, pero no se usó para avanzar en el contraste con un alto cociente señal/ruido (CSR) para mejorar el contraste con más ruido. En otro concepto relacionado con la redundancia de imágenes multicontraste, se demostró la regularización para la reconstrucción de detección comprimida de imágenes multicontraste submuestreadas.

El documento USno-break space - U+00A02015/282719no-break space - U+00A0A1, Fielden et al. , describe la adquisición de datos de imágenes de perfusión y datos de imágenes anatómicas correspondientes a un área de interés de un sujeto. Los pesos de filtro para una función de coste que se aplicará a los datos de imagen de perfusión se determinan en función de la imagen anatómica. Se aplica la función de coste que contiene los pesos de filtro determinados a los datos de imagen de perfusión para generar datos de imagen mejorados asociados con la actividad fisiológica del sujeto en el área de interés.

El documento DE 10 2010 041 107 A1, Siemens AG, describe la adquisición y reconstrucción de datos de imágenes volumétricas médicas de un paciente y la reconstrucción de datos de imágenes sin procesar. Los datos de imagen sin procesar se filtran linealmente usando un filtro de recepción de bordes. Se crea una imagen de borde a partir de los datos de imagen suavizados y la imagen de borde y los datos de imagen suavizados sin procesar se superponen con diferentes factores de peso negativos para crear una imagen amplificada de borde para visualización.

Lovedeep: "Medical Image Denoising Using Convolutional Denoising Autoencoders (Eliminación de ruido de imágenes médicas usando codificadores automáticos de eliminación de ruido convolucional)", 16th International Conference on Data Mining Workshops (16.ª conferencia internacional sobre talleres de prospección de datos) (ICDMW) de IEEE de 2016, IEEE, 12 de diciembre de 2016, páginas 241-246 describe codificadores automáticos de eliminación de ruido construidos con capas convolucionales que se usan para eliminar ruido de forma eficiente de imágenes médicas incluso para muestras pequeñas. Las imágenes heterogéneas se pueden combinar para incrementar el tamaño de la muestra y aumentar el rendimiento de eliminación de ruido.

Koziarski et al.: "Deep Neural Image Denoising (Eliminación de ruido de imágenes neuronales profundas)", 10 de septiembre de 2016, Big Data Analytics in Social and Ubiquitous Context: 5th International Workshop on Modeling Social Media (análisis de macrodatos en un contexto social y no binario: 5.º taller internacional sobre modelado de las redes sociales), MSM 2014 describe una arquitectura de red neuronal convolucional capaz de eliminar el ruido de imágenes.

Ha habido desarrollos recientes en la investigación del aprendizaje profundo. Específicamente, los avances recientes en la red neuronal convolucional (CNN) para el reconocimiento de imágenes con una red residual profunda y la superresolución usando CNN han demostrado ser una gran promesa para mejorar la resolución de imágenes. En los últimos 5 años, las técnicas de aprendizaje profundo han avanzado en el rendimiento de la visión artificial, específicamente, en el reconocimiento de imágenes. La estrategia de red residual profunda (ResNet) se ha validado como estructura de red superior para redes neuronales convolucionales (CNN) porque su conexión de derivación ayuda al rendimiento de las CNN. Estos avances de las CNN proporcionan una capacidad sobrehumana de reconocimiento a los algoritmos de visión artificial. Sin embargo, no está claro que el modelo se pueda entrenar mejor para obtener imágenes médicas, ya que hay muchos menos conjuntos de datos disponibles para el entrenamiento y las redes profundas típicamente necesitan miles o millones de muestras debido a la cantidad de parámetros en el modelo. Además, no está claro qué estructura de red es la mejor para las imágenes médicas debido a las propiedades intrínsecas de las imágenes médicas en el sentido de que no son lo mismo que reconocer

objetos comunes dentro de las fotografías. Por último, no se conoce completamente cómo asegurarse de que el modelo no introduzca artefactos que no están en la imagen o pierda el detalle de la patología que el modelo no ha visto en los datos de entrenamiento.

Los procedimientos de CNN de superresolución (SR) se usan para generar superresolución para imágenes y vídeos (múltiples fotogramas). En una demostración con 91 imágenes (de un conjunto de datos de referencia público), los modelos CNNSR pueden lograr un rendimiento bueno y similar en comparación con el modelo entrenado en un gran conjunto de datos (ImageNet con millones de subimágenes). Esto se debe a que el tamaño del modelo CNNSR (aproximadamente 10K) no es tan grande como el modelo usado para otros procedimientos de reconocimiento de imágenes. Además, las muestras de entrenamiento que ve el modelo se pueden contar como parches locales más pequeños, lo que lleve a decenas de miles de parches para las 91 imágenes completas. Adicionalmente, las relativamente pocas muestras ya pueden capturar suficiente variabilidad de parches de imágenes naturales. Los trabajos de SR intentan lograr un mejor rendimiento para la percepción estética, pero no abordan la necesidad de evitar a la vez que se conservan los detalles y la patología en las imágenes médicas.

La IRM con marcado de espín arterial (ASL) usa la diferencia de señal entre la imagen marcada y la de control para cuantificar la perfusión sanguínea. Es una poderosa técnica de IRM y se aplica cada vez más para la investigación, el estudio y el diagnóstico clínico de enfermedades neurológicas, cerebrovasculares y psiquiátricas. Sin embargo, los mapas de perfusión de ASL adolecen típicamente de un CSR bajo debido a la sustracción de la señal. El CSR se puede aumentar si las exploraciones ASL se repiten tres o más veces para que las clínicas logren una calidad de imagen aceptable. Sin embargo, esta repetición de las exploraciones aumenta significativamente el tiempo de prueba. El ASL multirretraso (eASL) propuesto recientemente puede compensar el efecto de varios retrasos de tránsito para mejorar la sensibilidad de la medición de la perfusión. Sin embargo, la adquisición de diferentes retrasos aumenta además el coste del tiempo y da lugar a un CSR y a una resolución aún más bajos debido a las limitaciones de tiempo.

Lo que se necesita es un procedimiento para eliminar el ruido de imágenes, en lugar de generar una superresolución, que mejore las imágenes médicas multicontraste.

RESUMEN DE LA INVENCIÓN

Para abordar las necesidades de la materia, se proporciona un procedimiento para acortar el tiempo de obtención de imágenes para el diagnóstico y la obtención de imágenes funcionales que incluye la obtención de al menos dos imágenes de entrada de un sujeto, usando un generador de imágenes médicas, donde cada imagen de entrada incluye un contraste diferente, generar una pluralidad de copias de las imágenes de entrada del sujeto usando filtrado de medio no local (NLM), usando un ordenador programado adecuadamente, donde cada copia de la imagen de entrada del sujeto incluye diferentes características espaciales, obtener al menos una imagen de referencia del sujeto, usando el generador de imágenes médicas, donde al menos una imagen de referencia del sujeto incluye características de imagen que son diferentes de las imágenes de entrada del sujeto, entrenar un modelo de red profunda, usando el aumento de datos en el ordenador programado adecuadamente para ajustar de forma adaptativa los parámetros del modelo para aproximar la imagen de referencia de un conjunto inicial de imágenes de entrada, y genera una imagen de calidad mejorada del sujeto, para su análisis por parte de un médico. Una vez que se establecen los parámetros del modelo, se pueden obtener imágenes de mejor calidad sin necesidad de adquirir una imagen de referencia.

Según un aspecto de la invención, el generador de imágenes médicas incluye un generador de imágenes por resonancia magnética (IRM) o un escáner de tomografía computarizada (TC).

En otro aspecto de la invención, el aumento de datos incluye recortar, rotar o dar la vuelta a las imágenes de entrada del sujeto.

En un aspecto adicional de la invención, las características de obtención de imágenes de al menos una imagen de referencia del sujeto que son diferentes de las imágenes de entrada del sujeto incluyen un CSR más alto, una resolución más alta, menos artefactos, un contraste de imagen diferente, una imagen obtenida usando un generador de imágenes por TC, o una imagen obtenida usando un generador de imágenes IRM.

En todavía otro aspecto de la invención, el conjunto de datos incluye un conjunto de datos de marcado de espín arterial (ASL), un conjunto de datos de IRM o un conjunto de datos de TC.

Según un aspecto de la invención, el aumento de datos incluye entrenar un modelo de red profunda en una pluralidad de parches de las imágenes de entrada del sujeto para el aumento de datos, donde las imágenes de salida del sujeto se vuelven a ensamblan a partir de parches de imágenes de entrada individuales.

En otro aspecto de la invención, la información multicontraste se usa como una regularización para el NLM para mejorar la eliminación de ruido regularizada y evitar un suavizado excesivo.

En un aspecto adicional de la invención, el aumento de datos incluye además el uso de las imágenes de entrada del sujeto y las salidas de filtros no lineales como entradas para el modelo de red profunda, donde las imágenes de entrada del sujeto se adquieren a partir del marcado de espín arterial (ASL) y otras imágenes con contraste de un cerebro, donde el filtrado de NLM se usa en la imagen de ASL y se regulariza usando las otras imágenes con contraste, donde el aumento de datos se usa en todas las imágenes de entrada del sujeto y en las imágenes creadas a partir de los filtros de NLM, donde todos los datos aumentados encajan en el modelo de red profunda. Aquí, el modelo de red profunda incluye el uso de parches multicontraste de las otras imágenes para convolución y deconvolución con las imágenes de entrada del sujeto que eluden el uso de un conjunto de datos completo para permitir el aprendizaje residual.

En todavía otro aspecto de la invención, las imágenes de entrada y la imagen de referencia proceden de diferentes generadores de imágenes médicas, donde la imagen de entrada del sujeto incluye una imagen IRM del sujeto que se usa para predecir una imagen de TC del sujeto.

Según un aspecto de la invención, las imágenes de entrada del sujeto, la pluralidad de copias de las imágenes de entrada del sujeto y la al menos una imagen de referencia del sujeto incluyen un conjunto de datos.

En otro aspecto de la invención, la red profunda entrenada se aplica para mejorar y eliminar el ruido de cualquier imagen médica de relativa baja calidad.

BREVE DESCRIPCIÓN DE LOS DIBUJOS

La figura 1 muestra un diagrama de flujo de un algoritmo de procesamiento de imágenes para mejorar el contraste objetivo de la imagen, según una realización de la invención.

Las figuras 2A-2B muestran diagramas de flujo de (2A) entrenamiento mejorado y (2B) algoritmos de aplicación para la eliminación de ruido de ASL, según una realización de la invención.

DESCRIPCIÓN DETALLADA

La invención actual proporciona un procedimiento para mejorar la calidad de imagen de imágenes médicas. La invención proporciona un nuevo marco de aprendizaje profundo de extremo a extremo para tomar datos de imágenes sin procesar y resultados de filtros no lineales, que incluyen imágenes sin procesar a las que se les ha eliminado el ruido con diferentes niveles de eliminación de ruido, y añadir datos de imágenes multicontraste que tienen información anatómica similar con diferentes contrastes, y generar datos de imagen mejorados con mejor calidad en términos de resolución y CSR. El marco de extremo a extremo de la invención actual logra un mejor rendimiento y una mayor velocidad.

En una realización, la invención mejora la calidad de imagen de las imágenes IRM que típicamente tienen un CSR y una resolución bajos, por ejemplo, imágenes IRM con marcado de espín arterial (ASL). La invención mejora la calidad de la imagen usando información multicontraste de otras imágenes con la misma estructura anatómica pero diferentes contrastes, y usando la técnica de aprendizaje profundo como estrategia efectiva y eficiente.

La figura 1 muestra un diagrama de flujo de una realización de la invención que incluye usar un generador de imágenes médicas para obtener una imagen de un sujeto de interés, donde la imagen es una imagen de baja resolución y relativamente con ruido que se introduce en un ordenador programado adecuadamente. En un aspecto opcional, también se introducen en el ordenador otras imágenes del mismo sujeto de interés (anatomía) y que tienen diferentes contrastes. Según la realización actual, se aplican múltiples filtros de medios no locales (NLM) que tienen diferentes parámetros a las imágenes de entrada, para generar múltiples versiones de las imágenes filtradas. Se realiza el registro conjunto de imágenes multicontraste y, a continuación, se generan imágenes multicontraste. Una imagen con diferentes contrastes y la misma anatomía proporcionada para el aumento de datos, donde el aumento de datos incluye recortar, rotar, trasladar y dar la vuelta. La imagen de un sujeto de interés se introduce de nuevo con las imágenes multicontraste. El algoritmo proporciona un generador de imagen a parche para ejecutar completamente el aumento. Estas imágenes aumentadas se introducen en una red profunda que comprende aprendizaje residual y una red neuronal convolucional. El modelo se entrena usando una imagen de referencia del contraste objetivo que tiene un CSR relativamente alto y una mejor resolución, donde esta imagen se introduce en un generador de imagen a parche para generar un parche de imagen de referencia del contraste objetivo que tiene un CSR alto y una mejor resolución para su uso en entrenamiento. Se genera un parche mejorado del contraste objetivo y se introduce en un generador de parche a objetivo, donde se genera una imagen mejorada del contraste objetivo, que tiene un CSR y una resolución mejorados.

La invención actual proporciona una eliminación de ruido superior usando un procedimiento basado en datos que entrena un modelo (aprendizaje supervisado) basado en imágenes reales, de alto CSR y de alta resolución adquiridas usando una exploración más larga. El modelo es un mapeo sumamente no lineal procedente de una imagen de baja calidad a imágenes de referencia de alta calidad. De esta forma, el modelo logra un rendimiento significativamente mejor para su aplicación específica. En una realización, las imágenes multicontraste se usan para

la eliminación de ruido, donde la información de la imagen multicontraste se usa en múltiples etapas que incluyen, pero no se limitan a, mejorar un algoritmo de medio no local (NLM) en el que los pesos de similitud usados para la eliminación de ruido dependen de la similitud de múltiples contrastes entre imágenes o porciones recortadas de las imágenes. La mejora surge, en parte, porque el CSR en las imágenes multicontraste es mucho más alto que en la imagen original, tal como ASL, etc., para mejorar, de modo que la similitud se pueda calcular con mayor precisión. Aquí, si hay una patología que solo se puede ver en algunos de los contrastes, la diferencia se mostrará en una comparación multicontraste y la lesión no se suavizará en exceso. La invención usa la información multicontraste como regularización para filtros no lineales, como un filtro de NLM, que regulariza mejor la eliminación de ruido y evita un suavizado excesivo.

Además, las imágenes multicontraste se introducen directamente en la red profunda, donde la red profunda incorpora las múltiples versiones de las imágenes sin ruido (ASL) y también las imágenes multicontraste. Debido a la red profunda, el modelo se entrena a continuación para ensamblar de forma no lineal todas las imágenes sin ruido para lograr la mejor calidad de imagen, que incluye un mejor CSR y una mejor resolución.

En la práctica, al usar el procedimiento de CNN con aceleración de hardware (GPU) impulsada por marcos de aprendizaje profundo, el procedimiento puede lograr mejoras de forma eficiente.

Previamente, las redes profundas tomaban normalmente millones de muestras para optimizar su rendimiento de reconocimiento. En los aspectos de aprendizaje profundo de la invención actual, de manera análoga a los modelos CNN-SR, el entrenamiento se realiza con conjuntos de datos muy pequeños. Lo que aprende el modelo es el residuo de la diferencia entre los datos de imagen sin procesar y los datos de imagen reales, que son más dispersos y menos complejos de aproximar usando la estructura de red. La invención usa conexiones de derivación para permitir el aprendizaje residual. Aquí, se usa una red residual y la salida del modelo directo es la estimación residual/error entre imágenes de baja y alta calidad. Esta estrategia de "entrenamiento residual" reduce la complejidad del entrenamiento y logra un mejor rendimiento, donde el nivel de salida es pequeño, lo que reduce la probabilidad de introducir artefactos grandes en la imagen, incluso, cuando el modelo no predice perfectamente. Esto es importante para imágenes médicas, ya que es inaceptable introducir grandes artefactos.

Pasaremos ahora al aspecto de la solución basada en parches de la invención actual. La estrategia basada en parches en el entrenamiento y su aplicación a la red profunda reduce la complejidad del modelo y resuelve la falta de datos médicos, donde el aumento de datos incluye tomar parches de imágenes para mejorar los resultados finales. La invención lleva a cabo este "aumento de características" tomando las salidas de los filtros no lineales como entrada para la red profunda, lo que mejora el rendimiento. El modelo está configurado para el entrenamiento en los parches de imagen multicontraste, a continuación, el modelo genera la versión mejorada de los parches, donde se usan más tarde para sintetizar la imagen completa. Se pueden derivar miles de parches de imágenes mediante el aumento de datos, que incluye recortes, rotaciones y vueltas de una única imagen. Esta estrategia basada en parches reduce la complejidad del modelo, acelera el entrenamiento, resuelve la falta de datos, evita el sobreajuste y añade más aleatorización de datos, lo que ayuda a lograr un mejor rendimiento. El entrenamiento residual y la información multicontraste también ayudan a reducir los artefactos y a conservar la patología.

Además, la invención usa información multicontraste de formas no convencionales e implementa una estructura CNN-SR + ResNet para lograr una mejor calidad de imágenes médicas.

Hay muchas posibles aplicaciones para esta invención, donde se pueden tomar imágenes de exploraciones previas y futuras y generar una versión mejorada de las imágenes. Esto es valioso para todos los dispositivos de obtención de imágenes médicas y sistemas PACS. En una realización, la invención se puede usar como parte de la reconstrucción en el escáner para generar directamente una versión mejorada de las imágenes, que se puede integrar en una variedad de aplicaciones de secuencias de imágenes médicas. En una realización adicional, la invención proporciona una aplicación específica para IRM con marcado de espín arterial (ASL), que se usa en el diagnóstico de muchas enfermedades neurológicas. Las aplicaciones a otros tipos de imágenes se encuentran dentro del alcance de la invención, y se podrían imaginar mejoras inmediatas para la obtención de imágenes ponderadas por difusión (DTI) multidireccionales sumamente muestreadas. Además, la invención puede permitir la mejora de la reconstrucción de imágenes submuestreadas, tales como IRM rápida.

La IRM con marcado de espín arterial (ASL) es una potente herramienta de obtención de imágenes neurológicas que proporciona mapas de perfusión cuantitativos. Sin embargo, los mapas de perfusión de ASL adolecen típicamente de un CSR y resolución bajos. El promedio de múltiples exploraciones (valor Nex alto) puede mejorar el CSR, pero a costa de incrementar significativamente el tiempo de adquisición. En una realización, la invención actual proporciona una técnica para mejorar la calidad de imagen de ASL con CSR y/o resolución potenciados mediante la incorporación de la información de imágenes multicontraste, el uso de filtrado multilateral de variante espacial no lineal y no local, y el entrenamiento de un modelo de red profunda para ajustar de forma adaptativa el nivel final de eliminación de ruido y potenciar aún más el CSR para mejorar la calidad de la imagen. Varios experimentos in vivo realizados por los autores de la invención demuestran el rendimiento superior de la invención, que acelera significativamente la adquisición de ASL y mejora la calidad de la imagen. La invención actual proporciona una solución a este problema urgente de carencia de CSR en ASL y eASL, que mejora

significativamente la calidad de la imagen y acelera las pruebas de ASL.

Para resumir aquí, hay tres innovaciones principales de esta invención que incluyen incorporar información multicontraste en la eliminación de ruido de ASL, usar un filtro de variante espacial no lineal para evitar el suavizado excesivo de los bordes y generar el resultado final de eliminación de ruido/restauración usando una red profunda.

Las figuras 2A-2B muestran un diagrama de flujo de un entrenamiento y aplicación de algoritmos según la invención actual, que incluye generar ASL sin ruido con diferentes niveles de eliminación de ruido usando un filtro guiado multilateral basado en una imagen de ASL de bajo CSR y otra IRM con contraste. El algoritmo crea parches de IRM multicontraste a partir de ASL original de bajo CSR que comprende sus múltiples versiones sin ruido e IRM anatómica registrada conjuntamente, donde se muestran T2w y PDw. Además, el algoritmo entrena una red profunda para aprender la eliminación de ruido final de los parches de IRM multicontraste y el parche correspondiente en la imagen de ASL de alto CSR de referencia. Por último, el algoritmo sintetiza el ASL sin ruido final a partir de los parches de salida.

En un filtrado guiado multilateral ejemplar que usa información multicontraste, para un examen de ASL siempre hay una imagen ponderada por densidad de protones (PDw) tomada sin marcado. También es muy probable que haya exploraciones anatómicas adicionales como T1w, T2w, FLAIR, etc., ya que, a menudo, se adquieren como parte de un examen de IRM de rutina. Estas imágenes comparten la información de estructura básica y tienen un CSR mucho más alto. Aquí, la invención usa un filtro guiado multilateral para realizar un promedio ponderado de variante de ubicación para cada píxel. El peso se basa en las diferencias de la señal de ASL y las señales de RM multicontraste anatómica (T2w, PDw, etc.) de cada píxel y sus píxeles vecinos. A diferencia de la eliminación de ruido convencional basada en el modelo gaussiano o en ondículas, esta etapa es un filtro de variante de ubicación no lineal y no local, que tiende a conservar mejor las estructuras y evitar un suavizado excesivo. El parámetro de ponderación aquí controla el suavizado.

Al formar la imagen con parches de IRM multicontraste, después de eliminar el ruido, se obtienen múltiples ASL eliminados con diferentes parámetros de ponderación. Se forma un montón de imágenes multicontraste que incluyen: el ASL con bajo CSR original, múltiples imágenes de ASL sin ruido con diferentes niveles de suavizado e imágenes T2w y PDw registradas conjuntamente. A continuación, se recortan pequeños parches multicontraste (16 x 16, etc.) de estas imágenes multicontraste. La eliminación de ruido final funciona en estos montones locales de parches, lo que acelera el cálculo, reduce la complejidad del modelo e incrementa el tamaño de la muestra de entrenamiento (~10.000 de un corte) para impedir cualquier sobreajuste en el entrenamiento de la red profunda.

Después, se implementa un proceso que usa la red profunda para la reconstrucción de eliminación de ruido, que incluye entrenar una red profunda para generar los resultados finales de eliminación de ruido y restauración. Aquí se utiliza una red neuronal convolucional-deconvolucional con la estructura como muestra la imagen en la **figura 2A**. La entrada de la red profunda son los parches de IRM multicontraste, y la salida es la versión final sin ruido. La red profunda se entrena en un conjunto de cortes o conjuntos de imágenes usando ASL con alto CSR/alta resolución como real y se aplica en diferentes exploraciones y cortes. El ASL sin ruido final se forma sintetizando los parches de salida.

De vuelta ahora a la **figura 2B**, para aplicar el algoritmo, la eliminación de ruido de la señal de ASL no lineal se proporciona usando un filtro guiado no local (NLM) y multicontraste. A continuación, los parches se generan a partir de imágenes de referencia de ASL con alto CSR, imágenes de ASL sin procesar con e bajo CSR, imágenes de ASL sin ruido multinivel e imágenes de RM anatómicas. La red profunda entrenada se aplica para generar la restauración de imágenes no lineales a partir de parches multicontraste. Por último, la forma de imagen restaurada de los parches almacenados se genera para su salida e implementación por parte de un médico.

Se realizaron múltiples experimentos in vivo. Se validó el rendimiento del algoritmo para mejorar el CSR. Usando 6 repeticiones (Nex = 6) como un ASL con alto CSR de referencia, los resultados muestran que el algoritmo según la invención actual reduce el error y el ruido para el ASL con bajo CSR adquirido con Nex = 1, que es una reducción en más de cuatro veces del tiempo de adquisición absoluto en comparación con la exploración de referencia con alto CSR. A continuación, se validó el rendimiento del algoritmo para mejorar tanto el CSR como la resolución en ASL multirretraso. Los resultados demuestran una mejor calidad de imagen para cada tiempo de retraso, así como mejores mapas de tiempo de tránsito calculados a partir de ellos.

Los experimentos in vivo demuestran que la invención proporciona un rendimiento superior para restaurar la imagen de ASL con un CSR y/o resolución más altos (efectivamente como ~ 6x Nex o 4+ reducción de tiempo). En comparación con los resultados de reconstrucción y eliminación de ruido convencionales, la invención actual puede reducir mejor el ruido, conservar estructuras y proporcionar métricas funcionales más detalladas, tales como CBF y mapas de tiempo de tránsito. La invención también se puede aplicar para complementar la obtención de imágenes en paralelo y la detección comprimida para la adquisición adicional de exploraciones de ASL.

La presente invención se ha descrito ahora de acuerdo con varias realizaciones ejemplares, que pretenden ser ilustrativas en todos los aspectos, en lugar de restrictivas. Por tanto, la presente invención es capaz de muchas

variaciones en la implementación detallada, que un experto en la materia puede derivar de la descripción contenida en esta solicitud. Por ejemplo, en las imágenes de RM convencionales de mayor resolución y CSR (tales como las imágenes T2w o FLAIR) también se podría eliminar el ruido de forma efectiva usando esta estrategia. O, el modelo se podría entrenar para tomar un conjunto de imágenes IRM como entrada y una TC como imagen de referencia, para crear una estimación de la TC del paciente en la situación en la que no se adquirió una.

5

REIVINDICACIONES

1. Un procedimiento para acortar el tiempo de obtención de imágenes para el diagnóstico y la obtención de imágenes funcionales, que comprende:

a) obtener al menos dos imágenes de entrada de un sujeto, usando un generador de imágenes médicas, donde cada una de dichas imágenes de entrada comprende un contraste diferente;

b) generar una pluralidad de copias de dichas imágenes de entrada de dicho sujeto usando filtrado de medio no local (NLM), usando un ordenador programado adecuadamente, donde cada copia de dicha imagen de entrada de dicho sujeto comprende diferentes características espaciales;

c) obtener al menos una imagen de referencia de dicho sujeto, usando dicho generador de imágenes médicas, donde dicha al menos una imagen de referencia de dicho sujeto comprende características de obtención de imágenes que son diferentes de dichas imágenes de entrada de dicho sujeto;

d) entrenar un modelo de red profunda, usando aumento de datos en dicho ordenador programado adecuadamente, para ajustar de forma adaptativa los parámetros del modelo para aproximar dicha imagen de referencia a partir de un conjunto inicial de dichas imágenes de entrada; y

e) generar una imagen de calidad mejorada de dicho sujeto, para su análisis por parte de un médico.

2. El procedimiento según la reivindicación 1, donde dicho generador de imágenes médicas comprende un generador de imágenes por resonancia magnética (IRM) o un escáner de tomografía computarizada (TC).

3. El procedimiento según la reivindicación 1, donde dicho aumento de datos se selecciona de entre el grupo que consiste en recortar, rotar y dar la vuelta a dichas imágenes de entrada de dicho sujeto.

4. El procedimiento según la reivindicación 1, donde dichas características de obtención de imágenes de dicha al menos una imagen de referencia de dicho sujeto que son diferentes de dichas imágenes de entrada de dicho sujeto se seleccionan de entre el grupo que consiste en un CSR más alto, una resolución más alta, menos artefactos, un contraste de imagen diferente, una imagen obtenida usando un generador de imágenes por TC y una imagen obtenida usando un generador de imágenes IRM.

5. El procedimiento según la reivindicación 1, donde dicho conjunto de datos se selecciona de entre el grupo que consiste en un conjunto de datos de marcado de espín arterial (ASL), un conjunto de datos de IRM y un conjunto de datos de TC.

6. El procedimiento según la reivindicación 1, donde dicho aumento de datos comprende entrenar un modelo de red profunda en una pluralidad de parches de dichas imágenes de entrada de dicho sujeto para dicho aumento de datos, donde las imágenes de salida de dicho sujeto se vuelven a ensamblar a partir de dichos parches de imagen de entrada individuales.

7. El procedimiento según la reivindicación 1, donde la información multicontraste se usa como una regularización para dicho NLM para mejorar la eliminación de ruido regularizada y evitar un suavizado excesivo.

8. El procedimiento según la reivindicación 1, donde dicho aumento de datos comprende además usar dichas imágenes de entrada de dicho sujeto y salidas de filtros no lineales como entradas para dicho modelo de red profunda, donde dichas imágenes de entrada de dicho sujeto se adquieren a partir de marcado de espín arterial (ASL) y otras imágenes con contraste de un cerebro, donde dicho filtrado de NLM se usa en dicha imagen de ASL y se regulariza usando dichas otras imágenes con contraste, donde dicho aumento de datos se usa en todas dichas imágenes de entrada de dicho sujeto y en imágenes creadas a partir de dichos filtros de NLM, donde todos dichos datos aumentados se ajustan a dicho modelo de red profunda.

9. El procedimiento según la reivindicación 8, donde dicho modelo de red profunda comprende usar parches multicontraste de dichas otras imágenes para la convolución y deconvolución con dichas imágenes de entrada de dicho sujeto que eluden el uso de un conjunto de datos completo para permitir aprendizaje residual.

10. El procedimiento según la reivindicación 1, donde dichas imágenes de entrada y dicha imagen de referencia proceden de dichos generadores de imágenes médicas diferentes, donde dicha imagen de entrada de dicho sujeto comprende una imagen IRM de dicho sujeto que se usa para predecir una imagen de TC de dicho sujeto.

11. El procedimiento según la reivindicación 1, donde dichas imágenes de entrada de dicho sujeto, dicha pluralidad de copias de dichas imágenes de entrada de dicho sujeto y dicha al menos una imagen de referencia de dicho sujeto comprende un conjunto de datos.

12. El procedimiento según la reivindicación 1, donde dicha red profunda entrenada se aplica para mejorar y eliminar el ruido de cualquier imagen médica de relativa baja calidad






FIG. 1

Etapas 1: Eliminación de ruido de señal de ASL no lineal usando filtro guiado multicontraste y no local (NLM)



Entrenamiento

Etapas 2: Generar parches a partir de imágenes de ASL de referencia con alto CSR, ASL con bajo CSR sin procesar, ASL sin ruido multinivel y de RM anatómicas



Etapas 3: Entrenamiento de red profunda para aprender la restauración de imágenes no lineales a partir de parches multicontraste



Etapas 4: Generar la imagen restaurada a partir de parches almacenados





FIG. 2A


Etap 1: Eliminación de ruido de señal de ASL no lineal usando filtro guiado multicontraste y no local (NLM)



reconocimiento original

más regulación usando eliminación de ruido no lineal

Etap 2: Generar parches a partir de imágenes de ASL de referencia con alto CSR, ASL con bajo CSR sin procesar, ASL sin ruido multinivel y de RM anatómicas



Etap 3: Aplicar la red profunda entrenada para generar la restauración de imágenes no lineales a partir de parches multicontraste



Etap 4: Generar la imagen restaurada a partir de parches



FIG. 2B