

19



OFICINA ESPAÑOLA DE
PATENTES Y MARCAS

ESPAÑA



11 Número de publicación: **2 697 611**

51 Int. Cl.:

G06K 9/40 (2006.01)

G06T 5/00 (2006.01)

12

TRADUCCIÓN DE PATENTE EUROPEA

T3

86 Fecha de presentación y número de la solicitud internacional: **16.04.2012 PCT/US2012/033852**

87 Fecha y número de publicación internacional: **18.10.2012 WO12142624**

96 Fecha de presentación y número de la solicitud europea: **16.04.2012 E 12770973 (1)**

97 Fecha y número de publicación de la concesión europea: **15.08.2018 EP 2697740**

54 Título: **Método para determinar un mapa de pixon en la reconstrucción de imagen iterativa**

30 Prioridad:

15.04.2011 US 201161476012 P

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

25.01.2019

73 Titular/es:

**SIEMENS MEDICAL SOLUTIONS USA, INC.
(100.0%)
40 Liberty Blvd.
Malvern, PA 19355-1406 , US**

72 Inventor/es:

YAHIL, AMOS

74 Agente/Representante:

CARVAJAL Y URQUIJO, Isabel

ES 2 697 611 T3

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

DESCRIPCIÓN

Método para determinar un mapa de pixon en la reconstrucción de imagen iterativa

Campo de la invención

5 La presente invención se refiere a un método para la reconstrucción y mejora de la señal, y más específicamente, a un método para reducir de forma adaptativa el ruido en un objeto de entrada.

Antecedentes de la invención

10 La extracción óptima de los datos contenidos dentro de una señal requiere la eliminación de defectos como el ruido y las limitaciones instrumentales. Un área clave en la que se busca la extracción y reconstrucción optimizadas de datos es el campo de mejora de la imagen. Incluso cuando los instrumentos se pueden hacer virtualmente sin ruido, las firmas instrumentales relacionadas con la resolución espacial, espectral o temporal finita permanecen. En este punto, se requiere la reconstrucción de la imagen para eliminar las firmas instrumentales. Las aplicaciones de mejora de la imagen, y las fuentes de ruido y otros factores que pueden afectar negativamente la extracción de datos, cubren un amplio rango que incluye la observación astronómica y la exploración planetaria, donde las fuentes pueden ser débiles y la interferencia atmosférica introduce ruido y distorsión, vigilancia militar y de seguridad, donde la luz puede ser baja y el movimiento rápido de los objetivos produce un contraste y un desenfoque deficientes, las imágenes médicas, que a menudo sufren de falta de claridad, y las imágenes de video, donde la transmisión y las limitaciones del instrumento, y la necesidad de una respuesta en tiempo real, pueden afectar negativamente a la nitidez y detalle de la imagen.

20 El procesamiento digital de imágenes se ha desarrollado para proporcionar reconstrucciones robustas y de alta calidad de datos borrosos y ruidosos recopilados por una variedad de sensores. El campo existe porque es imposible construir instrumentos de imagen que produzcan imágenes consistentemente nítidas y no corrompidas por el ruido de medición. No obstante, es posible reconstruir matemáticamente la imagen subyacente a partir de datos no ideales obtenidos de instrumentos del mundo real para que la información presente pero oculta en los datos pueda extraerse con menos borrosidad y ruido. Muchos de estos métodos utilizan un proceso en el que se construye un modelo predictivo y se compara con los datos para evaluar la precisión del ajuste del modelo a los datos.

25 A lo largo de esta descripción escrita, "datos" se refiere a cualquier cantidad medida, a partir de la cual se estima una "imagen" desconocida a través del proceso de reconstrucción de la imagen. El término imagen denota la solución estimada o la verdadera imagen subyacente que da origen a los datos observados. La discusión generalmente deja en claro qué contexto se aplica; en casos de posible ambigüedad, se utiliza el "modelo de imagen" para denotar la solución estimada. Tenga en cuenta que los datos y la imagen no necesitan ser similares e incluso pueden tener una dimensionalidad diferente, por ejemplo, las reconstrucciones tomográficas buscan determinar una imagen 3D a partir de datos 2D proyectados. Un término alternativo a la imagen es "objeto", que transmite la idea de que el modelo puede ser más general que una imagen. Los dos términos se utilizan como sinónimos en lo sucesivo.

35 Los estadísticos han buscado durante mucho tiempo restringir los parámetros utilizados para ajustar los datos con el fin de mejorar la interpretación y la precisión predictiva del ajuste. Las técnicas estándar son la selección de subconjuntos, en la que algunos de los parámetros no son importantes y se excluyen del ajuste (por ejemplo, Miller 2002), y la regresión de cresta, en la que los valores de los parámetros se restringen agregando un término de regularización a la función de mérito utilizada en el ajuste (por ejemplo, Tikhonov 1963). Tibshirani (1996) combinó los dos métodos en una técnica conocida como Least Absolute Shrinkage and Selection Operator (LASSO).

40 La necesidad de limitar el número de parámetros en un ajuste es imperativa para problemas no determinados o mal determinados, en los que el número de parámetros es mayor o comparable al número de puntos de datos. Como ya subrayaron los creadores de los métodos estadísticos de cuadrados mínimos (Gauss 1809) y máxima probabilidad (Fisher 1912, 1922), estos métodos solo son válidos en el límite asintótico en el que el número de puntos de datos excede ampliamente el número de parámetros ajustados. Lejos de este límite asintótico, el ruido se ajusta como señal y el ajuste pierde su poder interpretativo y predictivo.

45 Puetter et al (2005) revisa numerosos algoritmos de reconstrucción en uso actual, incluidos los métodos de reconstrucción de imágenes iterativos, que ajustan de forma iterativa los modelos de imagen a los datos. Muchos esquemas iterativos de la técnica anterior que están diseñados para converger a la solución de máxima probabilidad convergen lentamente, incluso cuando se terminan antes para evitar el sobreajuste. La convergencia se puede lograr más rápidamente usando la matriz de Hessian de derivadas parciales de segundo orden de la función de mérito con respecto a la variable (Hesse 1876). Desafortunadamente, incluso utilizando este enfoque, la matriz de Hess es demasiado grande para ser calculada cuando se trata de los problemas a gran escala que se encuentran con frecuencia en la reconstrucción de imágenes, por ejemplo, donde la imagen contiene una gran cantidad de píxeles con emisiones significativas. En tales casos, los elementos de la matriz pueden numerarse en trillones. Las matrices de este tamaño simplemente no pueden ser procesadas por los ordenadores actuales, ni almacenadas en la memoria.

El deseo de restringir el número de parámetros en la escasez de problemas no determinados o pobremente determinados, como se le llama hoy en día, se basa en el concepto más abstracto de complejidad mínima (Solomonoff 1964; Kolmogorov 1965; Chaitin 1966), que se remonta al trabajo medieval de William de Ockham, quien abogó por la parsimonia de los postulados. En pocas palabras, en igualdad de condiciones, una explicación más simple es mejor que una más compleja.

Encontrar una solución a la dispersión, por ejemplo, al agregar un término de regularización de la norma l_0 a la función de mérito, es un problema difícil de N-P, en el que el esfuerzo computacional aumenta más rápidamente que cualquier polinomio en el número de parámetros. Esto ha llevado a la sustitución de la norma l_0 con una norma l_1 (Chen, Donoho y Saunders 1999), por lo que la optimización del ajuste con respecto a los parámetros se convierte en un problema convexo solucionable. Candès, Romberg y Tao (2004) fueron un paso más allá y mostraron cómo reducir aleatoriamente la cantidad de datos necesarios para el ajuste en una condición de incoherencia, una técnica conocida como detección comprimida. Donoho (2006) mostró que, bajo una condición similar de incoherencia entre las funciones de base utilizadas en la parametrización, la solución de la norma l_1 mínima es también la solución más dispersa.

Las desventajas de los métodos de la norma l_1 son dobles. Primero, muchos problemas de interés simplemente no satisfacen la condición de incoherencia y no son adecuados para los métodos de la norma l_1 . En segundo lugar, incluso cuando satisfacen la condición de incoherencia, los problemas a gran escala requieren un esfuerzo computacional excesivo. Por lo tanto, aunque son problemas convexos y pueden resolverse en principio, no pueden aplicarse en la práctica a problemas actuales con millones o más parámetros, un problema que también afecta a los métodos estadísticos tradicionales. Donoho et al (2006) discuten cómo aplicar la aleatoriedad de manera más eficiente a problemas a gran escala sin el uso de una norma l_1 .

El método pixon es una técnica eficiente para obtener soluciones mínimamente complejas de datos basados en píxeles, incluidos problemas a gran escala, sin exigir una escases estricta y sin la condición de incoherencia requerida por los métodos que utilizan la norma l_1 (Ver, por ejemplo, Piña y Puetter 1993; Puetter & Yahil 1999; Puetter, Gosnell & Yahil 2005, y la patente de EE. UU. Nos. 5,912,993, 6,353,688, 6,490,374, 6,895,125, 6,993,204, 7,863,574, 7,928,727, 8,014,580, 8,026,846, 8,058,601, 8,058,625, 8,086,011, 8,090,179, 8,094,898, 8,103,487). El método pixon es, por lo tanto, útil para problemas inversos a gran escala indeterminados o poco determinados, como la reconstrucción de imágenes o el análisis espectral. La complejidad mínima se logra al suavizar de forma adaptativa en cada ubicación de píxel el núcleo más amplio entre una biblioteca de núcleos, de modo que al suavizar esto y todos los núcleos más estrechos proporciona un ajuste adecuado a la huella de datos del píxel en cuestión. El mapa que especifica qué núcleo usar en cada píxel se denomina mapa pixon.

En su forma actual, una reconstrucción pixon consta de tres pasos. Primero, reconstruye una "pseudoimagen" sin ninguna restricción de pixon. Segundo, esta pseudoimagen se usa para determinar el mapa de pixon. En tercer lugar, la imagen final se obtiene mediante una reconstrucción restringida guiada por el mapa de pixon. Los pasos dos y tres se pueden repetir varias veces, pero esto generalmente no es necesario en la práctica, siempre que se obtenga una pseudoimagen razonable en el primer paso. Ver, Puetter & Yahil (1999), Puetter et al (2005) y Pat. U.S. Nos. 5,912,993, 6,353,688, 6,490,374, 6,895,125, 6,993,204, 7,863,574, 7,928,727, 8,014,580, 8,058,601, 8,058,625, 8,086,011, 8,090,179, 8,094,898, y 8,103,487 para las más completas discusiones del método pixon y su aplicación.

La figura 2 ilustra un sistema 200 de imágenes genérico con un detector 210 de imágenes y una unidad 220 de reconstrucción de pixon. La reconstrucción se basa en un método de pixon que utiliza un mapa P de pixon, que interactúa con un algoritmo 230 de reconstrucción de pixon. El método de pixon se refiere a un método que suaviza cada punto en el espacio objeto (en adelante, un "punto de objeto") asignando una forma o volumen a cada punto de objeto como base para el suavizado de pixon. El espacio de objetos es el espacio en el que se define el resultado de la reconstrucción de la imagen y que corresponde a un dominio del que se creó una imagen utilizando el sistema 200 de imágenes. (Cabe señalar que "espacio de imagen" es un término sinónimo de "espacio de objeto", y los dos términos se usan indistintamente a continuación). Un espacio de datos correspondiente viene dado por los puntos de datos medidos con el detector de imágenes 210.

El método pixon proporciona una reconstrucción de alta calidad de un objeto I de imagen en el espacio de objetos a partir de un conjunto d de datos medidos en el espacio de datos. Como método de reconstrucción adaptativo espacialmente, el método pixon aplica una operación de suavizado motivada por datos a cada punto de objeto. Al hacerlo, el método de pixon utiliza el principio de complejidad mínima al asignar a cada punto de objeto una función de núcleo de pixon, que es la base para la operación de suavizado. Dentro de la unidad 220 de reconstrucción de pixon, el mapa P de pixon define cuál de las funciones del núcleo de pixon se asigna a cada uno de los puntos del objeto.

En el sistema 200 de imágenes, el detector 210 de imágenes detecta y comunica el conjunto d de datos medidos a la unidad 220 de reconstrucción de pixon. La unidad 220 de reconstrucción de pixon utiliza los algoritmos de reconstrucción de pixon especialmente adaptados 230 para reconstruir el conjunto d de datos adquiridos en un objeto I de imagen. Al hacerlo, el algoritmo 230 de reconstrucción de pixon usa una matriz H del sistema para describir las

propiedades del sistema 200 de imágenes, y para estimar un objeto de imagen mejorado iterativamente ajustando el modelo de datos, que es la base para el objeto I de imagen. El objeto I de imagen, por ejemplo, se muestra en una pantalla 240 utilizando técnicas de representación bien conocidas.

5 Para cada punto de objeto, el mapa P de pixon proporciona una función de núcleo de pixon que se determina sobre la base de un método de complejidad mínima. Esta función de núcleo de pixon se usa en una operación de suavizado de pixon aplicada en el espacio de objetos.

10 El método pixon también puede habilitar la detección comprimida en forma de súper resolución, utilizando la normatividad de la imagen y la complejidad mínima para reconstruir una imagen con píxeles más finos que aquellos con los que se obtienen los datos. Esto no es una violación del teorema de muestreo debido a Nyquist (1928) y Shanon (1949) debido a las condiciones adicionales de no negatividad y complejidad mínima (por ejemplo, Puetter et al 2005). Las frecuencias espaciales más allá del límite de difracción, que están truncadas en los datos, pueden reconstruirse de manera similar en la imagen. El documento US2008/0270465 divulga un método para reconstrucción de imágenes de "mínimos cuadrados no negativos"

15 La figura 3 ilustra un flujo de proceso de ejemplo del método pixon. El suavizado de Pixon se aplica secuencialmente a un algoritmo de reconstrucción estándar.

20 Usando un algoritmo de reconstrucción estándar, la imagen de entrada se ajusta a un conjunto d de datos medidos (paso 300). De acuerdo con el uso descrito anteriormente del operador de núcleo K de pixon, la estimación resultante de la imagen se llama pseudoimagen. El mapa P de pixon se determina utilizando la pseudoimagen y el conjunto d de datos medidos (paso 310). La pseudoimagen también es el objeto inicial para la operación de suavizado de pixon (paso 320). Durante la operación (320) de suavizado de pixon, cada punto de objeto de la pseudoimagen se suaviza sobre una función de núcleo de pixon. (En algunas variaciones de los métodos de pixon existentes, el mapa de pixon también se puede actualizar en cada iteración mediante el cálculo de la imagen actualizada.

25 Los métodos de reconstrucción de imágenes iterativos ajustan de manera iterativa los modelos de imágenes a los datos medidos y, por lo tanto, minimizan el efecto del ruido en la imagen final. El resultado de un algoritmo de reconstrucción es una imagen aproximada que se ajusta al conjunto d de datos medidos de acuerdo con las reglas del algoritmo.

En el método pixon, se puede usar una imagen aproximada como objeto de entrada para el suavizado de pixon, para la reconstrucción de pixon y para la determinación del mapa de pixon.

30 El método pixon incluye una búsqueda de las funciones de núcleo pixon más amplias posibles en cada punto del espacio de objetos que, en conjunto, admiten el ajuste adecuado de un objeto al conjunto d de datos medidos. En particular, el mapa de pixon asigna a cada punto de objeto una función específica del núcleo de pixon.

35 Puede haber inconvenientes en el paso de calcular primero una pseudoimagen a partir de la cual se puede determinar el mapa de pixon. Este proceso requiere más cálculos y corre el riesgo de introducir artefactos en la pseudoimagen, lo que puede sesgar el mapa de pixon y, por lo tanto, la reconstrucción final de la imagen. Además, la determinación del mapa de pixon no funciona bien si la transformación del espacio objeto a espacio de datos no es local (Bhatnagar & Cornwell 2004). Por ejemplo, en las imágenes de interferometría y resonancia magnética, los datos son las transformadas de Fourier de la imagen (más el ruido), con cada onda de Fourier (función básica de la imagen) que se extiende sobre toda la imagen. Otro ejemplo es la transformación parcialmente no local en tomografía. Los datos son proyecciones 2D de una imagen 3D (más ruido), una transformación que es local transversal a la dirección de proyección, pero no local a lo largo de la dirección de proyección.

40 En vista de lo anterior, existe la necesidad de un método mejorado para determinar el mapa de pixon dentro del método de pixon.

Resumen de la invención

45 De acuerdo con la invención en el presente documento, las dificultades mencionadas anteriormente del método de pixon de tres etapas se evitan al calcular y actualizar el mapa de pixon durante la iteración. El enfoque mejorado determina el mapa de pixon de una variable que se usa para actualizar la imagen en la iteración, es decir, una "variable de actualización", y suaviza esta variable de actualización durante la iteración. La imagen actualizada generalmente también se suaviza más al final de la iteración, utilizando el mapa de pixon determinado durante la iteración. Por el contrario, los métodos de pixon existentes determinan el mapa de pixon de la imagen después de que se haya actualizado y procedan a suavizar la imagen con ese mapa de pixon.

50 Según la presente invención, la variable de actualización depende del método de reconstrucción, pero es típicamente un gradiente de una función de mérito o un factor de actualización multiplicativo (por ejemplo, Puetter et al., 2005).

Esta variable de actualización es suavizada por los núcleos de pixon, y el núcleo seleccionado en cada ubicación de imagen es el más ancho para el cual la proporción entre el cuadrado del cambio en la variable de actualización debido al suavizado y la varianza de la variable de actualización es menor que un umbral predeterminado para ello y para todos los núcleos más estrechos. Por lo general, el mismo núcleo también se usa para suavizar la imagen actualizada en esa ubicación antes de pasar a la siguiente iteración. Un refinamiento adicional permite "núcleos interpolados".

En un aspecto de la invención, un método para reconstruir un modelo de objeto a partir de un conjunto de datos obtenido a partir de un proceso físico, en el que el conjunto de datos contiene ruido, comprende: recibir el conjunto de datos definido en un espacio de datos; construir un modelo de objeto en un espacio de objeto en el que el modelo de objeto comprende una pluralidad de puntos de objeto; idear una transformación del modelo de objeto de espacio de objeto a espacio de datos que resulta en un modelo de datos, en donde la transformación corresponde al proceso físico por el cual se obtiene el conjunto de datos; seleccionar una función de mérito para determinar un ajuste de un modelo de datos al conjunto de datos; determinar una variable de actualización del modelo de objetos en el espacio de objetos basado en la función de mérito; suavizar la variable de actualización para determinar una variable de actualización suavizada: convolucionando la variable de actualización con cada uno de una pluralidad de núcleos de pixon; y seleccionar para cada punto de objeto del objeto de entrada un núcleo de pixon que tenga un tamaño más grande que cumpla con un criterio mínimo predeterminado; generar un mapa de pixon mediante la asignación de índices en cada punto del objeto del objeto de entrada correspondiente al núcleo de pixon seleccionado; y generar una salida que comprenda un modelo de objeto sustancialmente sin ruido basado en los índices dentro del mapa de pixon. En una realización, la función de mérito se determina utilizando un método de gradiente conjugado y la variable de actualización es un negridente.

En otro aspecto de la invención, un medio legible por ordenador no transitorio que incluye software incluido incluye instrucciones para reconstruir un modelo de objeto a partir de un conjunto de datos obtenidos de un proceso físico, en el que el conjunto de datos contiene ruido, y las instrucciones incluyen: recibir el conjunto de datos definido en un espacio de datos; construir un modelo de objeto en un espacio de objeto en el que el modelo de objeto comprende una pluralidad de puntos de objeto; idear una transformación del modelo de objeto de espacio de objeto a espacio de datos que resulta en un modelo de datos, en donde la transformación corresponde al proceso físico por el cual se obtiene el conjunto de datos; seleccionar una función de mérito para determinar un ajuste de un modelo de datos al conjunto de datos; determinar una variable de actualización del modelo de objetos en el espacio de objetos basado en la función de mérito; suavizar la variable de actualización para determinar una variable de actualización suavizada: convolucionando la variable de actualización con cada uno de una pluralidad de núcleo de pixon; y seleccionando para cada punto de objeto del objeto de entrada un núcleo de pixon que tenga un tamaño más grande que cumpla con un criterio mínimo predeterminado; y generar un mapa de pixon mediante la asignación de índices en cada punto del objeto del objeto de entrada correspondiente al núcleo de pixon seleccionado. En una realización de ejemplo, la función de mérito se determina utilizando un método de gradiente conjugado y la variable de actualización es un negridente.

Breve descripción de los dibujos

La fig. 1 es un diagrama de bloques de un entorno informático general en el que se puede practicar la presente invención.

La fig. 2 es una vista general de un sistema de imágenes de la técnica anterior basado en el método pixon.

La fig. 3 es un diagrama de flujo que ilustra un ejemplo de reconstrucción de imágenes utilizando el enfoque de la técnica anterior para la reconstrucción de pixon.

La fig. 4 es un diagrama de flujo que ilustra un ejemplo de reconstrucción de imágenes utilizando el método de pixon según la presente invención.

La fig. 5 es un diagrama de flujo que ilustra un ejemplo de un proceso de reconstrucción de imagen alternativo utilizando el método de pixon.

La fig. 6 muestra una imagen cerebral de "verdad" SBD sin ruido, normal y de densidad de protones (PD).

La fig. 7 muestra el logaritmo (base 10) del valor absoluto de la transformada de Fourier de la imagen de la fig. 6 en el espacio de datos.

La fig. 8 muestra la imagen de la fig. 6 con ruido gaussiano aleatorio (blanco) agregado a la imagen con una desviación estándar del 3% del vóxel de imagen más brillante.

La fig. 9 muestra el logaritmo (base 10) del valor absoluto de la transformada de Fourier de la imagen de la fig. 8 en el espacio de datos.

La fig. 10 muestra los mismos datos que la fig. 9, con las frecuencias altas truncadas, correspondientes a la cobertura de frecuencia restringida a un tercio de las frecuencias disponibles. Los datos en la fig. 10 comprenden la entrada a las reconstrucciones de la imagen mostrada en las Figs. 11-14.

5 La fig. 11 muestra una transformada de Fourier inversa simple de los datos de la fig. 10, revelando dos tipos de artefactos: ruido correlacionado (no blanco) y timbres en los bordes afilados.

La fig. 12 muestra el resultado de una reconstrucción de pixon de los datos de la fig. 10 con un factor de pixon de 0.3.

La fig. 13 muestra el resultado de una reconstrucción de pixon de los datos de la fig. 10 con un factor de pixon de 0.5.

La fig. 14 muestra el resultado de las reconstrucciones de pixon de los datos de la fig. 10 con un factor de pixon 1.0.

Descripción detallada de la invención

10 Antes de describir aspectos de la presente invención, puede ser útil proporcionar una breve descripción de un entorno 100 de sistema informático adecuado (figura 1) en el que se puede implementar la invención. El entorno 100 de sistema informático es solo un ejemplo de un entorno informático adecuado y no pretende sugerir ninguna limitación en cuanto al alcance de uso o la funcionalidad de la invención. Tampoco se debe interpretar que el entorno 100 informático tiene dependencia o requisito relacionado con ninguna ni una combinación de componentes ilustrados en el entorno 100
15 operativo de ejemplo.

La invención es operativa con muchos otros propósitos generales o entornos o configuraciones de sistemas informáticos para propósitos especiales. Los ejemplos de sistemas informáticos, entornos y/o configuraciones bien conocidos que pueden ser adecuados para su uso con la invención incluyen, pero no están limitados a, ordenadores personales, ordenadores servidores, dispositivos portátiles o de ordenador portátil, sistemas multiprocesador,
20 sistemas basados en microprocesadores, decodificadores, dispositivos electrónicos de consumo programables, PC de red, miniordenadores, ordenadores centrales, sistemas telefónicos, entornos informáticos distribuidos que incluyen cualquiera de los sistemas o dispositivos mencionados anteriormente, y similares.

La invención se puede describir en el contexto general de instrucciones ejecutables por ordenador, tales como módulos de programa, que se ejecutan por un ordenador. Generalmente, los módulos de programa incluyen rutinas, programas, objetos, componentes, estructuras de datos, etc., que realizan tareas particulares o implementan tipos de datos abstractos particulares. Los expertos en la materia pueden implementar la descripción y/o las figuras en este documento como instrucciones ejecutables por ordenador, que pueden incorporarse en cualquier forma de medios legibles por ordenador que se describen a continuación.
25

La invención también puede ponerse en práctica en entornos informáticos distribuidos donde las tareas se realizan mediante dispositivos de procesamiento remoto que están vinculados a través de una red de comunicaciones. En un entorno informático distribuido, los módulos de programa pueden ubicarse en medios de almacenamiento informáticos locales y remotos, incluidos los dispositivos de almacenamiento de memoria.
30

Con referencia a la fig. 1, un sistema de ejemplo para implementar la invención incluye un dispositivo informático de propósito general en forma de un ordenador 110. Los componentes del ordenador 110 pueden incluir, pero no están limitados a, una unidad 120 de procesamiento, una memoria 130 del sistema y un bus 121 del sistema que acopla varios componentes del sistema, incluida la memoria del sistema, a la unidad 120 de procesamiento. El bus 121 del sistema puede ser cualquiera de varios tipos de estructuras de bus, incluido un bus de memoria o un controlador de memoria, un bus periférico y un bus local que utiliza cualquiera de una variedad de arquitecturas de bus. A modo de ejemplo, y no de limitación, tales arquitecturas incluyen el bus de Arquitectura Estándar de la Industria (ISA), el bus de Arquitectura de Micro Canal (MCA), el bus de ISA Mejorado (EISA), el bus local de la Asociación de Estándares de Electrónica de Video (VESA) y la Interconexión de Componentes Periféricos (PCI) bus también conocido como bus mezanine.
35
40

El ordenador 110 normalmente incluye una variedad de medios legibles por ordenador. Los medios legibles por ordenador pueden ser cualquier medio disponible al que pueda acceder el ordenador 110 e incluye tanto medios volátiles como no volátiles, medios extraíbles y no extraíbles. A modo de ejemplo, y no de limitación, los medios legibles por ordenador pueden comprender medios de almacenamiento informáticos y medios de comunicación. Los medios de almacenamiento informático incluyen medios volátiles y no volátiles, extraíbles y no extraíbles implementados en cualquier método o tecnología para el almacenamiento de información, como instrucciones legibles por ordenador, estructuras de datos, módulos de programas u otros datos. Los medios de almacenamiento en ordenador incluyen, pero no se limitan a, RAM, ROM, EEPROM, memoria flash u otra tecnología de memoria, CD-ROM, discos versátiles digitales (DVD) u otro almacenamiento de disco óptico, casetes magnéticos, cinta magnética, almacenamiento en disco magnético u otros dispositivos de almacenamiento magnético, o cualquier otro medio que pueda usarse para almacenar la información deseada y al que pueda acceder el ordenador 110. Los medios de
45
50

comunicación generalmente incorporan instrucciones legibles por ordenador, estructuras de datos, módulos de programa u otros datos en una señal de datos modulada, como una onda portadora u otro mecanismo de transporte, e incluye cualquier medio de entrega de información. El término “señal de datos modulados” significa una señal que

5 A modo de ejemplo, y no de limitación, los medios de comunicación incluyen medios cableados, como una red cableada o conexión directa, y medios inalámbricos, como acústicos, RF, infrarrojos y otros medios inalámbricos. Las combinaciones de cualquiera de los anteriores también deben incluirse dentro del alcance de los medios legibles por ordenador.

10 La memoria 130 del sistema incluye medios de almacenamiento informático en forma de memoria volátil y/o no volátil, como la memoria de solo lectura (ROM) 131 y la memoria de acceso aleatorio (RAM) 132. Un sistema 133 básico de entrada/salida (BIOS), que contiene las rutinas básicas que ayudan a transferir información entre elementos dentro del ordenador 110, como durante el inicio, se almacena típicamente en la ROM 131. La RAM 132 generalmente contiene módulos de datos y/o programas a los que se puede acceder de inmediato y/o que actualmente están siendo operados por la unidad 120 de procesamiento. A modo de ejemplo, y no de limitación, la fig. 1 ilustra el sistema 134 operativo, los programas 135 de aplicación, otros módulos 136 de programa y los datos 137 de programa.

15 El ordenador 110 también puede incluir otros medios de almacenamiento informáticos volátiles/no volátiles extraíbles/no extraíbles. A modo de ejemplo solamente, la fig. 1 ilustra una unidad de disco duro 141 que lee o escribe en un medio magnético no volátil y no extraíble, una unidad 151 de disco magnético que lee o escribe en un disco 152 magnético no volátil extraíble y una unidad 155 de disco óptico que lee o escribe en un disco óptico no volátil extraíble 20 156, como un CD ROM u otro medio óptico. Otros medios de almacenamiento en ordenador extraíbles/no extraíbles, volátiles/no volátiles que se pueden usar en el entorno operativo de ejemplo, incluyen, pero no se limitan a, cassetes de cinta magnética, tarjetas de memoria flash, discos versátiles digitales, cinta de video digital, RAM de estado sólido, ROM de estado sólido, y similares. La unidad 141 de disco duro está típicamente conectada al bus 121 del sistema a través de una interfaz de memoria no extraíble como la interfaz 140, y la unidad 151 de disco magnético y la unidad 25 155 de disco óptico están conectadas típicamente al bus 121 del sistema mediante una interfaz de memoria extraíble, como como interfaz 150.

Las unidades y sus medios de almacenamiento informáticos asociados descritos anteriormente e ilustrados en la fig. 1, proporciona almacenamiento de instrucciones legibles por ordenador, estructuras de datos, módulos de programa y otros datos para el ordenador 110. En la Fig. 1, por ejemplo, la unidad 141 de disco duro se ilustra como sistema 30 144 operativo de almacenamiento, los programas 145 de aplicación, otros módulos 146 de programa y los datos de programa 147. Tenga en cuenta que estos componentes pueden ser iguales o diferentes al sistema 134 operativo, los programas 135 de aplicación, otros módulos 136 de programa y los datos 137 de programa. El sistema 144 operativo, los programas 145 de aplicación, otros módulos 146 de programa, y los datos 147 de programa reciben números diferentes aquí para ilustrar que, como mínimo, son copias diferentes.

35 Un usuario puede ingresar comandos e información en el ordenador 110 a través de dispositivos de entrada como un teclado 162, un micrófono 163 (que también puede representar la entrada provista a través de un teléfono) y un dispositivo 161 señalador, como un mouse, trackball o almohadilla táctil. Otros dispositivos de entrada (que no se muestran) pueden incluir un joystick, una almohadilla de juego, una antena parabólica, un escáner o similar. Estos y otros dispositivos de entrada a menudo se conectan a la unidad 120 de procesamiento a través de una interfaz 160 40 de entrada de usuario que está acoplada al bus del sistema, pero pueden conectarse mediante otras interfaces y estructuras de bus, como un puerto paralelo, un puerto de juegos o un bus serial universal (USB). Un monitor 191 u otro tipo de dispositivo de visualización también se conecta al bus 121 del sistema a través de una interfaz, como una interfaz 190 de video. Además del monitor, los ordenadores también pueden incluir otros dispositivos de salida periféricos, como los altavoces 197 y la impresora 196, que pueden conectarse a través de una interfaz 195 de salida 45 periférica.

El ordenador 110 puede operar en un entorno de red usando conexiones lógicas a uno o más ordenadores remotos, tal como un ordenador 180 remoto. El ordenador 180 remoto puede ser un ordenador personal, un dispositivo de mano, un servidor, un enrutador, un ordenador de red, un dispositivo de par u otro nodo de red común, y típicamente incluye muchos o todos los elementos descritos anteriormente en relación con el ordenador 110. Las conexiones 50 lógicas representadas en la fig. 1 incluye una red de área local (LAN) 171 y una red de área amplia (WAN) 173, pero también puede incluir otras redes. Dichos entornos de red son comunes en oficinas, redes de ordenadores de toda la empresa, intranets e Internet.

Cuando se utiliza en un entorno de red LAN, el ordenador 110 está conectado a la LAN 171 a través de una interfaz o adaptador 170 de red. Cuando se usa en un entorno de red WAN, el ordenador 110 generalmente incluye un módem 55 172 u otros medios para establecer comunicaciones a través de la WAN 173, como Internet. El módem 172, que puede ser interno o externo, puede conectarse al bus 121 del sistema a través de la interfaz 160 de entrada del usuario, u otro mecanismo apropiado. En un entorno de red, los módulos de programa representados en relación con el ordenador 110, o porciones de los mismos, pueden almacenarse en el dispositivo de almacenamiento de memoria remota. A modo de ejemplo, y no de limitación, la fig. 1 ilustra los programas 185 de aplicación remota que residen en

el ordenador 180 remoto. Se apreciará que las conexiones de red mostradas son de ejemplo, y se pueden usar otros medios para establecer un enlace de comunicaciones entre los ordenadores.

5 Dentro de esta solicitud, "pixon" se usa para indicar que un término, método, objeto, etc. se refiere al método de pixion, es decir, al uso de formas específicas de puntos de objetos cuando se suaviza un objeto de imagen como se describe en la patente de EE. UU. Nos. 5,912,993, 6,895,125 y otras patentes relacionadas. Por ejemplo, las formas asignadas están definidas por las funciones de núcleo de pixion, y el mapa P de pixion almacena la información sobre la cuál las funciones de núcleo de pixion están asignadas a cada punto de objeto.

Un ajuste a los datos es la solución a un problema inverso ruidoso. Los datos se modelan como

$$\mathbf{d} = \mathbf{H}(\mathbf{I}) + \boldsymbol{\varepsilon} \quad , \quad (1)$$

10 donde \mathbf{d} es una matriz que contiene los datos medidos, \mathbf{I} es una matriz que contiene los parámetros de ajuste, \mathbf{H} es la función de transformación del espacio de parámetros al espacio de datos, y $\boldsymbol{\varepsilon}$ es una matriz que contiene las contribuciones de ruido a los datos. Para propósitos de ilustración, se utiliza una notación apropiada para la reconstrucción de la imagen en la ecuación. (1), es decir, \mathbf{d} son datos de píxeles y \mathbf{I} es la imagen reconstruida. Sin embargo, no se pretende que este ejemplo sea limitativo, ya que la presente invención tiene amplias aplicaciones para cualquier problema inverso ruidoso que pueda resolverse utilizando el método de pixion.

Para muchas aplicaciones, la transformación \mathbf{H} es lineal y la ecuación (1) se puede escribir como

$$\mathbf{d} = \mathbf{HI} + \boldsymbol{\varepsilon} \quad , \quad (2)$$

20 donde \mathbf{d} e \mathbf{I} se tratan como vectores, y \mathbf{H} como una matriz, conocida como matriz del sistema. La siguiente discusión está restringida al caso lineal de la ecuación (2), pero puede generalizarse a problemas no lineales mediante la linealización, es decir, considerando un dominio de imagen limitado en el que $\mathbf{H}(\mathbf{I})$ es aproximadamente lineal.

Tenga en cuenta que, en realidad, \mathbf{d} y \mathbf{I} pueden ser multidimensionales y ni siquiera es necesario que tengan la misma dimensionalidad (por ejemplo, en tomografía). Pero los píxeles multidimensionales siempre se pueden organizar como vectores largos, y entonces uno puede pensar en \mathbf{H} como una matriz.

El modelo de datos

$$\mathbf{m} = \mathbf{HI} = \mathbf{d} - \boldsymbol{\varepsilon} \quad (3)$$

Es la parte de la señal no ruidosa de los datos. También es el valor esperado de los datos.

$$\mathbf{m} = \mathbf{E}(\mathbf{d}) \quad , \quad (4)$$

porque el valor esperado del ruido puede, sin pérdida de generalidad, establecerse de manera idéntica a cero para todos los puntos de datos

$$\mathbf{E}(\boldsymbol{\varepsilon}) \equiv 0 \quad . \quad (5)$$

La matriz de covarianza del ruido es, en general, distinta de cero y puede ser una función de la posición (ubicación del píxel) y/o el valor del modelo de datos.

$$\mathbf{V}(\boldsymbol{\varepsilon}) = \mathbf{V}(\mathbf{m}) \quad . \quad (6)$$

35 Normalmente, los puntos de datos son independientes, por lo que \mathbf{V} es una matriz diagonal, pero también puede haber datos correlacionados, en cuyo caso \mathbf{V} tiene elementos distintos de cero y fuera de la diagonal.

La reconstrucción de la imagen es el problema inverso de resolver la ecuación (2) o, más generalmente, la ecuación (1) para la imagen \mathbf{I} , dados los datos \mathbf{d} , una matriz \mathbf{H} del sistema y un modelo estadístico del ruido $\boldsymbol{\varepsilon}$. Se resuelve optimizando una función de mérito de los datos, dado el modelo de datos.

$$\mathbf{L} = \mathbf{L}(\mathbf{d}|\mathbf{m}) = \mathbf{L}(\mathbf{d}|\mathbf{HI}) \quad . \quad (7)$$

La elección de la función de mérito depende de las estadísticas de ruido. Por lo general, se considera que es la función de probabilidad de registro (LLF), que está relacionada con la probabilidad máxima (por ejemplo, Puetter et al 2005).

Para el ruido gaussiano, la LLF se reduce a χ^2

$$L = \chi^2 = \sum_i \sigma_i^{-2} [d_i - m_i]^2 = \sum_i \sigma_i^{-2} \left[d_i - \sum_{\alpha} H_{i\alpha} I_{\alpha} \right]^2 \quad \text{(LLF Gaussiano)} \quad (8)$$

- 5 donde la suma sobre i se ejecuta sobre los píxeles de datos, la suma sobre α se ejecuta sobre los píxeles de la imagen, y σ_i es la desviación estándar gaussiana del ruido en el píxel i . La LLF gaussiana tiene la ventaja de ser cuadrática en la imagen I , por lo que su gradiente con respecto a I es lineal en I .

Para el ruido de Poisson, la LLF es una función no lineal más complicada

$$L = 2 \sum_i [m_i - d_i \ln(m_i)] = 2 \sum_i \left[\sum_{\alpha} H_{i\alpha} I_{\alpha} - d_i \ln \left(\sum_{\alpha} H_{i\alpha} I_{\alpha} \right) \right] \quad \text{(LLF de Poisson),} \quad (9)$$

- 10 que puede resolverse mediante optimización no lineal (por ejemplo, Press et al 2007) o utilizando una función sustituta (Lange, Hunter & Yang 1999). Mighell (1999) propuso, en cambio, utilizar una aproximación cuadrática a la LLF de Poisson, que produce un modelo de datos imparcial, incluso en el límite de cuentas bajas.

$$\begin{aligned} \chi_y^2 &= \sum_i [d_i + 1]^{-1} [d_i + \text{Min}(d_i, 1) - m_i]^2 \\ &= \sum_i [d_i + 1]^{-1} \left[d_i + \text{Min}(d_i, 1) - \sum_{\alpha} H_{i\alpha} I_{\alpha} \right]^2 \quad \text{(\chi_y^2 de Mighell).} \end{aligned} \quad (10)$$

- 15 Existen numerosos métodos para optimizar la función de mérito, pero pocos son adecuados para problemas a gran escala, porque la matriz H del sistema y su transposición H^T se vuelven demasiado grandes para calcular o almacenar, incluso utilizando técnicas de matriz dispersa, y pueden solo ser aplicadas como operadores. Esto deja básicamente dos métodos: métodos de expectativa-maximización (EM) (Richardson 1972; Lucy 1974; Dempster, Laird & Rubin 1977; Shepp & Vardi 1982) o métodos de gradiente conjugado (CG) (Fox, Huskey & Wilkinson 1948; Hestenes & Stiefel 1952; Press et al 2007). La minimización de expectativas de subconjuntos ordenados (OSEM) es una variante acelerada de EM, que utiliza solo un subconjunto de los datos en cada iteración (Hudson y Larkin 1994). El mismo procedimiento también se puede aplicar a CG.

- 20 El método CG procede al encontrar gradientes descendentes mínimos de la función de mérito. Más conjuntamente, este utiliza direcciones de gradiente conjugado, que son combinaciones lineales de gradientes (por ejemplo, Press et al 2007). Un concepto útil es el de negridente, que se define como la mitad del negativo del gradiente de la función de mérito con respecto a la imagen. Para la función de mérito gaussiana, ecuación (8), el negridente es

$$G_{\alpha} = -\frac{\partial L}{2 \partial I_{\alpha}} = \sum_i H_{i\alpha} \sigma_i^{-2} \left[d_i - \sum_{\beta} H_{i\beta} I_{\beta} \right] \quad \text{(Negridente Gaussiano),} \quad (11)$$

En notación matricial vectorial, la ecuación (11) se puede escribir como

$$\mathbf{G} = \mathbf{H}^T \mathbf{V}^{-1} \mathbf{r} \quad , \quad (12)$$

dónde

$$\mathbf{r} = \mathbf{d} - \mathbf{m} = \mathbf{d} - \mathbf{HI} \quad (13)$$

son los residuos, y la varianza del ruido es

$$\mathbf{V} = \text{Diag}(\sigma^2) \quad \text{(Varianza de ruido Gaussiana),} \quad (14)$$

donde $\text{Diag}(\sigma^2)$ denota la matriz diagonal cuyos elementos diagonales son σ^2 , los cuadrados de las desviaciones estándar.

5 Para el ruido de Poisson, el negradiante de la función de mérito Mighell (1999) χ^2 es

$$G_\alpha = -\frac{\partial L}{2\partial I_\alpha} = \sum_i H_{i\alpha} [d_i + 1]^{-1} \left[d_i + \text{Min}(d_i, 1) - \sum_\beta H_{i\beta} I_\beta \right] \quad \text{(Negradiante de Mighell).} \quad (15)$$

El negradiante de Mighell Poisson también es lineal en la imagen I y se puede escribir en la notación compacta de vector-matriz de la ecuación (12), donde los residuos son

$$\mathbf{r} = \mathbf{d} + \text{Min}(\mathbf{d}, 1) - \mathbf{m} = \mathbf{d} + \text{Min}(\mathbf{d}, 1) - \mathbf{H}\mathbf{I} \quad \text{(Residuales de Mighell).} \quad (16)$$

10 y la varianza del ruido es

$$\mathbf{V} = \text{Diag}(\mathbf{d} + 1) \quad \text{(Varianza de ruido de Mighell)} \quad (17)$$

El método de CG se puede acelerar en gran medida agregando un preconditionador (por ejemplo, Golub & Van Loan 1996; Saad 2003), reemplazando el gradiente de la función de mérito con

$$\mathbf{G} = \mathbf{P}^{-1}\mathbf{H}^T\mathbf{V}^{-1}\mathbf{r} \quad \text{(Negradiante con preconditionador)} \quad (18)$$

15 donde la ecuación lineal

$$\mathbf{P}\mathbf{x} = \mathbf{b} \quad (19)$$

se puede resolver con facilidad. El método resultante se conoce como el método de gradiente de conjugado (PCG) preconditionado.

20 Las restricciones a menudo también pueden manejarse por el método de proyecciones en conjuntos convexos (Biemond, Lagendijk y Mersereau 1990). Por ejemplo, la normatividad, $I \geq 0$, se puede imponer después de cada iteración simplemente truncando los componentes negativos de la imagen a cero y continuando como si no hubiera truncamiento (Puetter et al. 2005). También es útil, en cada iteración, establecer a cero cualquier componente negativo de gradiente conjugado en píxeles con valor de imagen cero en esa iteración. Esto evita que estos píxeles participen en la minimización, solo para ver sus valores de imagen negativos resultantes truncados a cero al final de la minimización.

En la presente invención, el mapa de pixon se determina a partir de la variable de actualización y no a partir de la imagen después de que se haya actualizado, y la variable de actualización se suaviza de acuerdo con este mapa de pixon. Esto evita la necesidad de calcular una pseudoimagen inicial, ya que el mapa de pixon se actualiza y la variable de actualización se suaviza en cada iteración.

30 Para el método CG, la variable de actualización se toma como negradiante, ecuación (12). (Un negradiante preconditionado, la ecuación (18), se maneja de manera análoga. El negradiante es suavizado por los núcleos en una biblioteca de núcleo de pixon, y el núcleo seleccionado en cada ubicación de la imagen es el más ancho para el cual la proporción entre el cuadrado del cambio en el negradiante debido al suavizado y la varianza del negradiante es menor que un umbral predeterminado para él y todos los núcleos más estrechos.

Específicamente, se elige una biblioteca de funciones del núcleo, definida sobre el espacio de objetos

$$K^{(j)}(\boldsymbol{\tau}) \quad j = 1, \dots, J \quad . \quad (20)$$

El zeroth y los primeros momentos de las funciones del núcleo están configurados para

$$\mu_0^{(j)} = \int K^{(j)}(\boldsymbol{\tau}) d\boldsymbol{\tau} \equiv 1 \quad , \quad (21)$$

$$5 \quad \mu_1^{(j)} = \int \boldsymbol{\tau} K^{(j)}(\boldsymbol{\tau}) d\boldsymbol{\tau} \equiv 0 \quad , \quad (22)$$

y los segundos momentos están ordenados en orden creciente.

$$\mu_2^{(j)} = \int \boldsymbol{\tau}^2 K^{(j)}(\boldsymbol{\tau}) d\boldsymbol{\tau} \quad \mu_2^{(1)} < \mu_2^{(2)} < \dots < \mu_2^{(J)} \quad , \quad (23)$$

10 donde las integrales son aproximadas, en la práctica, por sumas sobre píxeles. Los segundos momentos se diseñan generalmente para formar una serie geométrica ascendente para la caracterización óptima de estructuras de imagen multiescala. Tenga en cuenta que la dimensionalidad es importante en las ecuaciones. (21) - (23); por lo tanto, los índices α de píxeles de imagen 1D utilizados anteriormente se reemplazan por los índices vectoriales $\boldsymbol{\tau}$ y \mathbf{x} .

Una serie de cambios $\Delta G^{(j)}$ se obtienen a su vez al convolucionar a su vez el negradyente con cada uno de los núcleos y restando el negradyente original

$$\Delta G^{(j)}(\mathbf{x}) = \int K^{(j)}(\boldsymbol{\tau}) G(\mathbf{x} + \boldsymbol{\tau}) d\boldsymbol{\tau} - G(\mathbf{x}) \quad . \quad (24)$$

15 El mapa de pixon es entonces una imagen de índices, de manera que, en cada píxel, el índice elegido es el más grande para el cual el cuadrado del cambio del negradyente suavizado es menor o igual que un p^2 múltiple del negradyente.

$$\mathbf{M}(\mathbf{x}) = \text{Max}_j \left\{ \Delta G^{(j)}(\mathbf{x})^2 \leq p^2 V(G(\mathbf{x})) \right\} \quad , \quad (25)$$

20 donde p es un factor de pixon, discutido a continuación. El negradyente suavizado se obtiene al agregar negradyente en cada píxel de imagen el cambio de negradyente suavizado que corresponde a su índice de pixon.

$$\tilde{G}(\mathbf{x}) = G(\mathbf{x}) + \Delta G^{(M(\mathbf{x}))}(\mathbf{x}) \quad . \quad (26)$$

25 Será fácilmente evidente a partir de la ecuación (25) que el factor p de pixon, que es ajustable por el usuario, controla la fuerza del suavizado de pixon. Una p más grande puede permitir que una j más grande satisfaga la ecuación (25) en cualquier píxel \mathbf{x} , lo que aumenta el valor de $M(\mathbf{x})$. El resultado es que el negradyente se suaviza más fuertemente, ecuación (26). Por el contrario, una p más pequeña puede restringir j a un valor más pequeño, disminuyendo así $M(\mathbf{x})$ y suavizando menos. El resultado es que el usuario puede ajustar p para establecer el intercambio entre el ruido y el suavizado. Una p más grande suprime el ruido mejor al precio de alguna pérdida de resolución, mientras que una p más pequeña conserva mejor la resolución al precio de un nivel de ruido más alto.

30 La figura 4 ilustra un diagrama de flujo de ejemplo, con el método mejorado para determinar el mapa de pixon en un proceso de reconstrucción de imágenes. En el paso 400, la reconstrucción de la imagen comienza optimizando una función de mérito de los datos d dado el modelo de datos de la ecuación (7). En la realización de ejemplo, se usa un método de gradiente conjugado (CG). En el paso 402, el método CG se usa para determinar el negradyente, que se usará como la variable de actualización (UV). En el paso 404, el negradyente es convolucionado con cada uno de los núcleos de la biblioteca 406 de núcleo de pixon para suavizar el UV. El núcleo seleccionado en cada ubicación de la imagen es el más ancho para el cual la proporción entre el cuadrado del cambio en la variable de actualización debido al suavizado y la varianza de la variable de actualización es menor que un umbral predeterminado para ella y para todos los núcleos más estrechos. El mapa 410 de pixon se forma utilizando una imagen de índices de los núcleos seleccionados. El mismo núcleo normalmente también se usa para suavizar la imagen 408 actualizada en esa misma ubicación antes de pasar a la siguiente iteración. De acuerdo con el método de pixon existente, la imagen iterativamente mejorada es la base de la imagen de salida I , que puede visualizarse en una pantalla y/o almacenarse en un medio de memoria.

Como se señaló anteriormente, la aplicación de ejemplo para la reconstrucción de imágenes no pretende ser limitativa, y el método mejorado es aplicable a cualquier proceso de reconstrucción de señales que utilice el método de pixon. Es posible generalizar las funciones del núcleo a funciones no locales, que realizan un suavizado más complicado. Por ejemplo, en una imagen de un edificio de apartamentos que contiene muchas ventanas idénticas, es posible suavizar todas las ventanas de la imagen usando un solo núcleo no contiguo. O los datos podrían no tener ningún significado geométrico, por ejemplo, los precios de las acciones, en cuyo caso la pixelización se reemplaza con algún esquema de indexación de las acciones. La integral de convolución, ecuación (24), se sustituye para tales sistemas por una relación más general

$$\mathbf{G}^{(j)}(\mathbf{x}) = \int K^{(j)}(\mathbf{x}, \mathbf{y}) \mathbf{G}(\mathbf{x}, \mathbf{y}) d\mathbf{y} \quad (27)$$

10 Por lo general, es beneficioso mantener una condición de normalización similar a la ecuación (21)

$$\mu_0^{(j)} = \int K^{(j)}(\mathbf{x}, \mathbf{y}) d\mathbf{y} \equiv 1 \quad (28)$$

pero las ecuaciones (22)-(23) ya no son significativas y deben ser reemplazadas por condiciones específicas del problema. El punto importante, en lo que respecta al método pixon, es que las funciones del núcleo mantienen un orden de preferencia, de modo que las ecuaciones (25)-(26) siguen siendo significativas.

15 Un refinamiento adicional es formar un mapa de pixon continuo con "índices fraccionarios" y "núcleos intermedios" mediante la interpolación entre los negradients de prueba. Esto suaviza el negradients aún más y/o permite el uso de menos funciones del núcleo. El índice de pixon intermedio se define como $M(\mathbf{x}) + \delta(\mathbf{x})$, donde $M(\mathbf{x})$ es el índice de pixon entero especificado por la ecuación (25) y $\delta(\mathbf{x})$ es el incremento que se interpola linealmente

$$\Delta \mathbf{G}(\mathbf{x})^2 / V(\mathbf{G}(\mathbf{x})) \text{ a } p^2$$

$$\delta(\mathbf{x}) = \left[p^2 V(\mathbf{G}(\mathbf{x})) - \Delta \mathbf{G}^{(M)}(\mathbf{x})^2 \right] / \left[\Delta \mathbf{G}^{(M+1)}(\mathbf{x})^2 - \Delta \mathbf{G}^{(M)}(\mathbf{x})^2 \right] \quad 0 \leq \delta(\mathbf{x}) < 1, \quad (29)$$

20 y la ecuación (26) se sustituye por

$$\tilde{\mathbf{G}}(\mathbf{x}) = \mathbf{G}(\mathbf{x}) + [1 - \delta(\mathbf{x})] \Delta \mathbf{G}^{(M(\mathbf{x}))} + \delta(\mathbf{x}) \Delta \mathbf{G}^{(M(\mathbf{x})+1)}, \quad (30)$$

que corresponde al uso de núcleos interpolados

$$\tilde{\mathbf{K}}(\mathbf{x}) = [1 - \delta(\mathbf{x})] \mathbf{K}^{(M(\mathbf{x}))} + \delta(\mathbf{x}) \mathbf{K}^{(M(\mathbf{x})+1)}. \quad (31)$$

25 El método de CG iterativo procede de la manera habitual (por ejemplo, Press et al 2007), con el negradients suavizado que reemplaza al original, no suavizado.

30 También es útil para suavizar el mapa de pixon continuo, $M(\mathbf{x}) + \delta(\mathbf{x})$, utilizando los núcleos interpolados de la ecuación (31). La razón detrás de esto es que el mapa de pixon debe ser suave en cada ubicación de la imagen en la escala del ancho del núcleo de pixon correspondiente al índice de pixon de esa ubicación. Por lo tanto, suavizar el mapa de pixon con él mismo no debe introducir un alisado adicional significativo en la imagen, sino que puede suavizar los artefactos, que pueden haberse introducido en el proceso de cálculo del mapa de pixon.

35 La imagen actualizada generalmente se suaviza aún más después de la iteración de los núcleos interpolados, ecuación (31). Sin embargo, el suavizado adicional puede llevar a cierta oscilación de la solución con la iteración, ya que los núcleos que suavizan correctamente el efecto negativo tienden a sobresuavizar la imagen completa. Una forma sencilla de apagar la oscilación es suavizar la imagen con un promedio del núcleo determinado en las iteraciones actuales y anteriores. (Para la primera iteración, el núcleo "anterior" es una función delta)

40 La figura 5 ilustra un diagrama de flujo de ejemplo, con el método mejorado para determinar el mapa de pixon en un proceso de reconstrucción de imágenes utilizando núcleos interpolados. En el paso 500, la reconstrucción de la imagen comienza optimizando una función de mérito de los datos dado el modelo de datos de la ecuación (7). En la realización de ejemplo, se usa un método de gradiente conjugado (CG). En el paso 502, el método CG se usa para determinar el negradients, que se usará como la variable de actualización (UV). En el paso 504, el negradients es

convolucionado con cada uno de los núcleos de la biblioteca 506 de núcleo pixon para suavizar la UV. El núcleo seleccionado en cada ubicación de la imagen es el más ancho para el cual la proporción entre el cuadrado del cambio en la variable de actualización y la varianza de la variable de actualización es menor que un umbral predeterminado para ella y para todos los núcleos más estrechos. El mapa 510 de pixon se forma utilizando una imagen de índices de los núcleos seleccionados. Una vez completada la convolución con los núcleos de la biblioteca de núcleo de pixon, se pueden generar núcleos interpolados en el paso 508 para suavizar aún más los UV que se utilizan para crear el mapa de pixon. El mismo núcleo interpolado se puede usar para suavizar la imagen 512 actualizada en esa ubicación antes de pasar a la siguiente iteración. De acuerdo con el método de pixon existente, la imagen iterativamente mejorada es la base de la imagen I de salida, que puede visualizarse en una pantalla y/o almacenarse en un medio de memoria.

La varianza del negradyente, que es crucial para la determinación del mapa de pixon, debe calcularse con cuidado, ya que la transposición matriz del sistema, H^T , ecuación (12), crea correlaciones entre los píxeles de la imagen, incluso si los datos son estadísticamente independientes. En algunos casos, por ejemplo, cuando H^T es una transformada de Fourier, la varianza del negradyente se puede calcular analíticamente. En otros casos, un método de Monte Carlo conveniente para calcular la varianza para problemas a gran escala es dividir los datos en una serie de subconjuntos de datos que no se superponen y calcular el negradyente G de la ecuación (12) para cada subconjunto, reemplazando el r residual con una realización aleatoria del ruido ϵ .

$$\mathbf{G}^{(s)} = \mathbf{H}^T \mathbf{V}^{-1} \boldsymbol{\epsilon}^{(s)} \quad \text{(Gradiente de subconjunto),} \quad (32)$$

donde el superíndice s designa subconjunto.

Dado que el valor esperado del ruido es cero en cada píxel, ecuación (5), el valor esperado de cada gradiente de subconjunto también es cero

$$E(\mathbf{G}^{(s)}) = 0 \quad . \quad (33)$$

En el límite de un gran número de subconjuntos, la varianza del negradyente se puede, por lo tanto, aproximar como la suma de los cuadrados de los gradientes de subconjuntos

$$V(\mathbf{G}) \approx \sum_k (\mathbf{G}^{(s)})^2 \quad . \quad (34)$$

El error relativo de la estimación de Monte Carlo de la varianza es

$$\Delta(V(\mathbf{G}))/V(\mathbf{G}) \sim S^{-1/2} \quad , \quad (35)$$

donde S es el número de subconjuntos.

Tenga en cuenta que para el ruido gaussiano, la varianza del negradyente depende solo de la desviación estándar del ruido, σ , y no de los datos o la imagen. Por lo tanto, no cambia con la iteración y solo debe calcularse una vez al comienzo de la reconstrucción de la imagen.

Lo mismo no se cumple estrictamente para el negradyente de Poisson del Mighell χ_γ^2 , porque los términos $[d_i + 1]^{-1}$ en la ecuación (15) depende de los datos de ruido de una manera complicada, no lineal. La práctica ha demostrado, sin embargo, que la varianza en estos términos es menos importante que la varianza de los residuos, ecuación (16), que se puede aproximar a partir de los datos

$$V(\mathbf{r}) \approx \mathbf{d} \quad \text{(Varianza de residuales de Poisson).} \quad (36)$$

Entonces, mientras que la varianza aproximada de los residuos en la ecuación (36) depende de los datos, no depende de la imagen. Por lo tanto, tampoco cambia con la iteración y también se puede calcular una vez al comienzo de la reconstrucción de la imagen.

Un método de pixon análogo también se puede aplicar a las reconstrucciones EM. Sin embargo, el problema es que la varianza del factor de actualización multiplicativa (Richardson 1972; Lucy 1974; Shepp y Vardi 1982) cambia con la iteración y debe volver a calcularse en cada iteración. Esto aumenta significativamente el esfuerzo computacional, además de la bien conocida recuperación de resolución más lenta del método EM, que requiere significativamente más iteraciones para el mismo grado de recuperación de resolución. En conjunto, estas consideraciones argumentan a favor del uso del método CG sobre el método EM.

Los siguientes ejemplos de aplicaciones del método de la invención para la reconstrucción de una señal de entrada utilizando el método pixon. Estos ejemplos son solo ilustrativos y no pretenden ser limitativos.

Ejemplos

10 Ejemplo 1: Síntesis de Apertura

La síntesis de apertura es un tipo de interferometría que mezcla señales de una matriz de telescopios para producir imágenes con la misma resolución angular que un instrumento del tamaño de toda la matriz. En cada separación y orientación, el patrón de lóbulos del interferómetro produce una salida que es un componente de la transformada de Fourier de la distribución espacial del brillo del objeto observado. La imagen (o "mapa") de la fuente se produce a partir de estas mediciones. La síntesis de apertura solo es posible si la amplitud y la fase de la señal entrante se miden con cada telescopio. Para las radiofrecuencias, esto es posible por la electrónica, mientras que, para las luces ópticas, el campo electromagnético no puede medirse directamente y correlacionarse en el software, sino que debe propagarse mediante ópticas sensibles e interferir ópticamente.

Para producir una imagen de alta calidad, se requiere un gran número de diferentes separaciones entre diferentes telescopios (la separación proyectada entre cualquiera de los dos telescopios como se ve desde la fuente de radio se denomina línea de base): se requieren tantas líneas de base diferentes como sea posible con el fin de obtener una imagen de buena calidad. El número de líneas de base (n_b) para una matriz de telescopios viene dado por $n_b = (n^2 - n) / 2$. Por ejemplo, entre los radiotelescopios astronómicos, el Very Large Array (VLA) tiene 27 telescopios que proporcionan 351 líneas de base independientes a la vez, mientras que el Atacama Large Millimeter/submillimetre Array (ALMA), ahora en construcción, tendrá, cuando se complete, 66 Telescopios, dando 2145 líneas de base independientes. La mayoría de los interferómetros de síntesis de apertura utilizan la rotación de la Tierra para aumentar el número de orientaciones de línea de base incluidas en una observación. Tomar datos en diferentes momentos proporciona mediciones con diferentes separaciones y ángulos de telescopio sin la necesidad de comprar telescopios adicionales o mover los telescopios manualmente, ya que la rotación de la Tierra mueve los telescopios a nuevas líneas de base. Se proporciona una mayor flexibilidad al permitir que los telescopios individuales se muevan a diferentes configuraciones, lo que le da a la matriz un potente "zoom" variable.

Otras aplicaciones de la síntesis de apertura incluyen el radar interferométrico de apertura sintética (IfSAR o InSAR), el radar de apertura sintética (SAR) y el radar de apertura sintética inversa (ISAR), el sonar de apertura sintética, la formación de haz y la magnetometría de apertura sintética.

Originalmente, se pensó que era necesario realizar mediciones en prácticamente cada longitud de línea de base y orientación hacia un máximo: una transformada de Fourier totalmente muestreada contiene formalmente la información exactamente equivalente a la imagen de un telescopio convencional con un diámetro de apertura igual a la línea de base máxima, por lo tanto, el nombre de síntesis de apertura. Se descubrió rápidamente que, en muchos casos, se podían obtener imágenes útiles con un conjunto relativamente disperso e irregular de líneas de base con la ayuda de métodos de reconstrucción de imágenes no lineales.

El método pixon es uno de esos métodos poderosos de reconstrucción de imágenes no lineales, pero su uso se vio obstaculizado por la naturaleza no local de la transformada de Fourier (Bhatnagar y Cornwell 2004). El nuevo método para determinar el mapa de pixon en la presente invención puede superar este obstáculo.

Ejemplo 2: Imagen de resonancia magnética

La imagen de resonancia magnética (MRI) es una técnica de imagen médica utilizada en radiología para visualizar estructuras internas detalladas. La MRI hace uso de la propiedad de la resonancia magnética nuclear para captar los núcleos de los átomos en el interior del cuerpo. Una máquina de MRI utiliza un potente campo magnético para alinear la magnetización de algunos núcleos atómicos en el cuerpo, y los campos de radiofrecuencia para alterar sistemáticamente la alineación de esta magnetización. Esto hace que los núcleos produzcan un campo magnético giratorio detectable por el escáner, y esta información se registra para construir una imagen del área escaneada del cuerpo. Los gradientes del campo magnético hacen que los núcleos en diferentes ubicaciones giren a diferentes velocidades. Al usar gradientes en diferentes direcciones, se pueden obtener imágenes 2D o volúmenes 3D en cualquier orientación arbitraria. La MRI se usa para obtener imágenes de cada parte del cuerpo y es particularmente

útil para tejidos con muchos núcleos de hidrógeno y poco contraste de densidad, como el cerebro, los músculos, el tejido conectivo y la mayoría de los tumores.

El cuerpo está compuesto en gran parte de moléculas de agua. Cada molécula de agua tiene dos núcleos de hidrógeno o protones. Cuando una persona está dentro del potente campo magnético del escáner, el momento magnético promedio de muchos protones se alinea con la dirección del campo. Un transmisor de radiofrecuencia se enciende brevemente, produciendo un campo electromagnético variable. Este campo electromagnético tiene la frecuencia correcta, conocida como frecuencia de resonancia, para ser absorbido y voltear el giro de los protones en el campo magnético. Después de que el campo electromagnético se apaga, los giros de los protones vuelven al equilibrio termodinámico y la magnetización en masa se vuelve a alinear con el campo magnético estático. Durante esta relajación, se genera una señal de radiofrecuencia, que se puede medir con las bobinas del receptor. Los protones en diferentes tejidos vuelven a su estado de equilibrio a diferentes tasas de relajación. Se pueden utilizar diferentes variables de tejido, incluida la densidad de giro, los tiempos de relajación T1 y T2 y los cambios de flujo y espectrales para construir imágenes. Al cambiar la configuración en el escáner, este efecto se utiliza para crear un contraste entre diferentes tipos de tejido corporal o entre otras propiedades, como en la MRI funcional (fMRI) y la MRI de difusión.

La información sobre el origen de la señal en el espacio 3D puede aprenderse aplicando campos magnéticos adicionales durante la exploración. Estos campos, generados al pasar corrientes eléctricas a través de bobinas de gradiente, hacen que la intensidad del campo magnético varíe dependiendo de la posición dentro del imán. Debido a que esto hace que la frecuencia de la señal de radio liberada también dependa de su origen de una manera predecible, la distribución de protones en el cuerpo puede recuperarse matemáticamente de la señal, generalmente mediante el uso de la transformada de Fourier inversa.

Una limitación importante de la MRI es la duración de la exploración, que resulta en un aumento de la incomodidad del paciente y un menor rendimiento del paciente. La exploración de MRI se puede acelerar de una de dos maneras, o una combinación de ellas. La duración de la exploración en cada frecuencia de radio se puede acortar, y/o el número de frecuencias de radio exploradas se puede reducir. Lo primero conduce a un aumento del ruido, mientras que lo último da como resultado una cobertura de frecuencia incompleta, que requiere técnicas similares a la síntesis de apertura. La reconstrucción de imágenes no lineales de pixon puede ayudar a reducir el ruido y compensar los datos de Fourier que faltan, como se muestra a continuación.

Desafortunadamente, no existe una "verdad fundamental" o un estándar de oro para el análisis de los datos de MRI adquiridos in vivo. Por lo tanto, se construyó una base de datos de cerebro simulado (SBD) en la Universidad de McGill (base de datos disponible públicamente en la World Wide Web en bic.mni.mcgill.ca/brainweb; Kwan, Evans & Pike 1999). El SBD contiene un conjunto de volúmenes de datos de MRI realistas producidos por un simulador de MRI. La comunidad de neuroimágenes puede utilizar estos datos para evaluar el rendimiento de varios métodos de análisis de imágenes en una configuración donde se conoce la verdad.

Actualmente, la SBD contiene datos simulados de MRI del cerebro basados en dos modelos anatómicos: esclerosis normal y múltiple (MS). Para ambos de estos, los volúmenes de datos tridimensionales completos se han simulado utilizando tres secuencias (T1, T2 y densidad de protones (PD)) ponderada y una variedad de grosores de corte, niveles de ruido y niveles de intensidad no uniforme. Estos datos están disponibles para verlos en tres vistas ortogonales (transversal, sagital y coronal) y para descargar. Más detalles sobre la creación de la SBD están disponibles a través de recursos públicos.

La figura 6 muestra una imagen cerebral de "verdad" SBD sin ruido, normal y de densidad de protones (PD), y la fig. 7 muestra el logaritmo (base 10) del valor absoluto de su transformación en espacio de datos. En ambas figuras, los paneles superiores muestran un corte coronal (panel izquierdo) y un corte sagital (panel derecho). El panel inferior es un corte transversal. La transformación del espacio objeto a espacio de datos consistió en transformadas de Fourier 2D, un corte transversal a la vez, y la visualización se desplazó transversalmente de manera cíclica, para mostrar que la frecuencia cero está en el centro. La figura 8 muestra la imagen de la fig. 6 con ruido gaussiano aleatorio (blanco) agregado a la imagen con una desviación estándar del 3% del vóxel de imagen más brillante. La figura 9 muestra la transformada de Fourier de la fig. 8 en el espacio de datos. Se ve que el ruido domina los datos a altas frecuencias (las periferias transversales de las pantallas de datos). La figura 10 muestra los mismos datos que la fig. 9, con las frecuencias altas truncadas, correspondientes a la cobertura de frecuencia restringida a un tercio de las frecuencias disponibles. Los datos en la fig. 10 comprenden la entrada a las reconstrucciones de la imagen.

La figura 11 muestra una transformada de Fourier inversa simple de los datos, mostrando dos tipos de artefactos. Primero, el ruido se ve claramente en toda la imagen; ya no es ruido blanco no correlacionado, debido al corte de frecuencia de los datos. En segundo lugar, el timbre se ve al lado de bordes afilados debido al fenómeno descrito por primera vez por Gibbs (1898, 1899). Un ajuste de mínimos cuadrados no negativos (NNLS) a los datos (no mostrado) es esencialmente idéntico a la transformada de Fourier inversa directa. Las diferencias entre esas imágenes aparecen solo en el fondo extracorpóreo, que es de poco interés y, de todos modos, muy pequeño. Se ven mejoras de imagen más significativas en las Figs. 12-14, que muestran el resultado de las reconstrucciones de pixon con factores de pixon de 0.3, 0.5 y 1.0, respectivamente. Todas las reconstrucciones reducen significativamente el ruido y el timbre de Gibbs,

pero no en la misma cantidad. Como se explicó anteriormente en el contexto de las ecuaciones (25)-(26), existe un equilibrio entre el ruido y el suavizado, que el usuario puede controlar con el factor p de pixon. Una p más grande suprime el ruido mejor al precio de alguna pérdida de resolución, mientras que una p más pequeña conserva mejor la resolución al precio de un nivel de ruido más alto. Este equilibrio es evidente en las Figs. 12-14, que muestran un alisado progresivamente más fuerte a medida que aumenta p , con una pérdida de resolución resultante.

Ejemplo 3: Tomografía computarizada

La tomografía computarizada (CT) proporciona un método de diagnóstico y medición para medicina e ingeniería de pruebas con la ayuda de las cuales se pueden examinar las estructuras internas de un paciente u objeto de prueba sin necesidad de realizar operaciones quirúrgicas en el paciente o dañar el objeto de la prueba. En este caso, se registran desde varios ángulos una serie de proyecciones del objeto a examinar, desde las cuales es posible calcular una descripción 3D del objeto.

Las imágenes tomográficas se producen al convertir proyecciones observadas (datos) en una imagen. Por ejemplo, en las imágenes de CT de rayos X, los haces de rayos X se dirigen a un objeto y los haces se atenúan en varias cantidades debido a las estructuras variables dentro del objeto. En el otro lado del objeto, los haces atenuados se miden con detectores. Tales proyecciones se producen en muchos ángulos diferentes alrededor del objeto. Estas mediciones no solo son ruidosas, sino que el nivel de ruido relativo depende de la cantidad de atenuación. Las proyecciones a través de materiales densos, como el hueso y especialmente el metal, tienen relaciones de señal a ruido menores que las proyecciones a través de la carne, el agua u otros materiales menos densos. Para hacer frente a las grandes y variadas fluctuaciones espaciales en el número de fotones detectados a menudo se requiere una técnica de suavizado estadístico para mejorar la imagen.

En los enfoques de reconstrucción de imágenes estadísticas, el problema se plantea como encontrar las imágenes que mejor se ajusten a las medidas de acuerdo con el modelo físico (posiblemente no lineal) y un modelo estadístico. El modelado estadístico adecuado puede llevar a imágenes de menor ruido, lo que permite reducciones en la dosis de rayos X para el paciente.

Ejemplo 4: Tomografía de emisión

La tomografía por emisión es una técnica de imágenes de medicina nuclear que produce una imagen 3D de los procesos funcionales en el cuerpo utilizando técnicas tomográficas similares a las utilizadas en la CT. La diferencia es que se inyecta un radioisótopo que emite rayos gamma o positrones (llamado radionúclido) en el torrente sanguíneo del paciente. Los radionúclidos emisores de rayos gamma emiten un solo fotón, y el método de imágenes se conoce como tomografía computarizada de emisión de fotón único (SPECT, o algunas veces SPET). Por el contrario, los positrones emitidos se aniquilan con electrones en el cuerpo para formar dos fotones que se mueven en direcciones opuestas, que se detectan en coincidencia; El método de imágenes se conoce como tomografía por emisión de positrones (PET).

La mayoría de las veces, el radioisótopo marcador, que es de interés sólo por sus propiedades radiactivas, se une a un ligando específico para crear un radioligando, que es de interés por sus propiedades de unión química a ciertos tipos de tejidos. Este matrimonio permite que la combinación de ligando y radioisótopo (el radiofármaco) sea transportada y unida a un lugar de interés en el cuerpo, que luego (debido a la emisión gamma directa o indirecta del isótopo) permite obtener imágenes de la concentración de ligando.

Las exploraciones nucleares se leen cada vez más junto con las exploraciones por CT o MRI, y la combinación proporciona información anatómica y metabólica (es decir, qué es la estructura y qué está haciendo bioquímicamente). Debido a que las imágenes nucleares son más útiles en combinación con las imágenes anatómicas, los escáneres nucleares modernos están ahora disponibles con escáneres de CT de fila multidetectores de alta gama integrados o, más recientemente, MRI. Debido a que las dos exploraciones se pueden realizar en secuencia inmediata, o incluso simultáneamente, durante la misma sesión, sin que el paciente cambie de posición entre los dos tipos de exploraciones, los dos conjuntos de imágenes se registran de manera más precisa, por lo que las áreas de anomalía en las imágenes nucleares se pueden correlacionar más perfectamente con la anatomía en las imágenes de CT o MRI. Esto es muy útil para mostrar vistas detalladas de órganos o estructuras móviles con mayor variación anatómica, que es más común fuera del cerebro.

Una técnica muy similar a la reconstrucción de la tomografía computarizada (CT) se usa comúnmente para producir la imagen en 3D, aunque el conjunto de datos recopilados en imágenes nucleares tiene muchos menos fotones que la CT, por lo que las técnicas de reconstrucción son más difíciles. El procesamiento de pixon se puede utilizar para mejorar la calidad de la imagen y/o reducir la dosis inyectada en el paciente.

Ejemplo 5: Análisis espectral

5 Un analizador de espectro mide la magnitud de una señal de entrada versus la frecuencia dentro del rango completo de frecuencia del instrumento. El uso principal es medir la potencia del espectro de señales conocidas y desconocidas. La señal de entrada que mide un analizador de espectro es eléctrica, sin embargo, las composiciones espectrales de otras señales, como las ondas de presión acústica y las ondas ópticas de luz, pueden considerarse mediante el uso de un transductor apropiado. Al analizar los espectros de señales eléctricas, se pueden observar la frecuencia dominante, la potencia, la distorsión, los armónicos, el ancho de banda y otros componentes espectrales de una señal que no son fácilmente detectables en las formas de onda en el dominio del tiempo. Estos parámetros son útiles en la caracterización de dispositivos electrónicos, como los transmisores inalámbricos.

10 Los tipos de analizadores de espectro son dictados por los métodos utilizados para obtener el espectro de una señal. Hay analizadores de espectro basados en sintonía de barrido y transformada de Fourier (FFT): un analizador de espectro con sintonía de barrido utiliza un receptor superheterodino para convertir una porción del espectro de la señal de entrada (usando un oscilador controlado por voltaje y un mezclador) a la frecuencia central de un filtro de paso de banda. Con una arquitectura superheterodina, el oscilador controlado por voltaje es barrido a través de un rango de frecuencias, permitiendo la consideración del rango completo de frecuencias del instrumento. Un analizador de 15 espectro FFT calcula la transformada rápida de Fourier, transformando así la señal de entrada en los componentes de su espectro de frecuencia. Algunos analizadores de espectro, como los analizadores de espectro en tiempo real, utilizan una técnica híbrida en la que la señal entrante primero se convierte a una frecuencia más baja utilizando técnicas superheterodinas y luego se analiza utilizando técnicas FFT.

20 Este es un ejemplo 1D, en el que el espectro (la "imagen") está relacionado con los datos de entrada mediante una transformada de Fourier no local. El método pixon puede aplicarse a dichos datos de manera análoga a los otros ejemplos de Fourier citados.

Referencias

1. Bhatnagar S, Cornwell TJ. 2004. *Astron. Astrophys.* 426:747-754
2. Biemond J, Lagendijk RL, Mersereau RM. 1990. *Proc. IEEE* 78:856-883
- 25 3. Candès EJ, Romberg J, Tao T. 2004, *IEEE Tans. Info. Thry.* 52:489-509
4. Chaitin GJ. 1966. *J. Assoc. Comput. Mach.* 13:547-569
5. Chen S, Donoho D, Saunders MA. 1999. *SIAM J. Sci. Comp.* 20:33-61
6. Dempster AP, Laird NM, Rubin DB. 1977. *J. R. Stat. Soc. B* 39:1-38
7. Donoho DL 2006, *Com. Pure Appl. Math.* 59:797-829
- 30 8. Donoho DL, Tsaig Y, Drori I, Starck JL. 2006. "Sparse Solution of Underdetermined Linear Equations by Stagewise Orthogonal Matching Pursuit", Stanford Technical Report
9. Fisher RA 1912. *Messenger Math.* 41:155c160
10. Fisher RA 1922. *Phil. Trans. Roy. Soc. A* 222:309-368
11. Fox L, Huskey HD, Wilkinson JH. 1948. *Quart. J. Mech. Appl. Math.* 1:149-173
- 35 12. Gauss CF 1809. *Theoria Motus Corporum Coelestium in sectionibus conicis solem ambientium*, English translation, 1963. *Theory of Motion of the Heavenly Bodies* (New York: Dover)
13. Gibbs JW. 1898. *Nature* 59:200
14. Gibbs JW. 1899. *Nature* 59:606
15. Golub GH, Van Loan CF. 1996. *Matrix Computations*, 3rd ed. (Baltimore: Johns Hopkins University Press)
- 40 16. Hesse LO. 1876. *Vorlesungen über Analytische Geometrie des Raumes, Insbesondere über Oberflächen Zweiter Ordnung*, (Leipzig: Teubner)
17. Hestenes MR, Stiefel E. 1952. *J. Res. Nat. Bur. Standards*, 49:409-436

18. Hudson HM, Larkin RS. 1994. IEEE Trans. Med. Imag. 13:601-609
19. Kolmogorov AN. 1965. Problems Inf. Transm. 1:4-7
20. Kwan RKS, Evans AC, Pike GB. 1999. IEEE Trans. Med. Imag. 18:1085-97
21. Lange K, Hunter DR, Yang I. 2000. J. Comp. Graph. Statist. 9:1-59
- 5 22. Lucy LB. 1974. Astron. J. 79:745-54
23. Mighell KJ. 1999. Astrophys. J. 518:380-393
24. Miller, A. 2002. Subset Selection in Regression, 2nd ed., (Boca Raton: Chapman & Hall/CRC)
25. Nyquist H. 1928. Trans. AIEE 47:617-644
26. Piña RK, Puetter RC. 1993. Publ. Astron. Soc. Pac. 105:630-637
- 10 27. Press WH, Teukolsky SA, Vetterling WT & Flannery BP. 2007. Numerical Recipes, 3rd ed., (Cambridge: Cambridge University Press)
28. Puetter RC, Gosnell TR & Yahil A. 2005. Annu. Rev. Astron. Astrophys. 43:139-194
29. Puetter RC, Yahil A. 1999. Astron. Soc. Pac. Conf. Ser. 172:307-316
30. Richardson W. 1972. J. Opt. Soc. Am. 62:55-59
- 15 31. Saad Y. 2003. Iterative Methods for Sparse Linear Systems, 2nd ed. (Philadelphia: SIAM)
32. Shannon CE. 1949. Proc. Institute. Radio Engineers. 37:10-21
33. Shepp LA, Vardi Y. 1982. IEEE Trans. Med. Imaging 1:113-22
34. Solomonoff RJ. 1964. Inf. Control 7:1-22
35. Tibshirani R. 1996. J. R. Statist. Soc. B 58:267-288
- 20 36. Tikhonov AN. 1963. Soviet Math. 4:1035-1038

REIVINDICACIONES

1. Un método implementado por ordenador para reconstruir un modelo de objeto a partir de un conjunto (d) de datos obtenido de un proceso físico, en el que el conjunto (d) de datos contiene ruido, el método comprende:
- 5 recibir en un entorno informático que comprende una unidad de procesamiento y una memoria del sistema el conjunto (d) de datos definido en un espacio de datos, en el que la unidad de procesamiento está programada para ejecutar los pasos de:
- construir un modelo de objeto en un espacio de objeto en el que el modelo de objeto comprende una pluralidad de puntos de objeto;
- 10 idear una transformación del modelo de objeto del espacio de objeto al espacio de datos que da como resultado un modelo de datos, en el que la transformación corresponde al proceso físico mediante el cual se obtiene el conjunto (d) de datos;
- seleccionar una función de mérito para determinar un ajuste del modelo de datos al conjunto de datos (d);
- determinar una variable de actualización del modelo de objetos en el espacio de objetos basado en la función de mérito;
- 15 suavizar la variable de actualización para determinar una variable de actualización suavizada mediante:
- convolucionar la variable de actualización con cada uno de una pluralidad de núcleos de pixon; y
- seleccionar para cada punto de objeto del modelo de objeto un núcleo de pixon que tenga un tamaño mayor que cumpla con un criterio mínimo predeterminado;
- 20 generar un mapa (P) de pixon asignando un índice a cada punto del objeto correspondiente al núcleo de pixon seleccionado;
- suavizar de forma iterativa la variable de actualización y actualizar el mapa (P) de pixon y el modelo de objetos basado en la variable de actualización suavizada hasta que se optimice la función de mérito; y
- generar una salida que comprenda un modelo de objeto sustancialmente sin ruido basado en los índices dentro del mapa (P) de pixon actualizado.
- 25 2. El método de la reivindicación 1, en el que la unidad de procesamiento está además programada para ejecutar el paso de suavizar el modelo de objeto mediante la convolución del modelo de objeto en cada punto del objeto con el núcleo de pixon seleccionado según el mapa (P) de pixon.
3. El método de la reivindicación 1, en el que la función de mérito se determina usando un método de gradiente conjugado.
- 30 4. El método de la reivindicación 3, en el que la variable de actualización es un negridente.
5. El método de la reivindicación 3, que comprende además añadir un preconditionador.
6. El método de la reivindicación 1, en el que la unidad de procesamiento está además programada para, después de la etapa de convolucionar la variable de actualización, ejecutar la etapa de restar la variable de actualización para determinar un cambio de variable de actualización.
- 35 7. El método de la reivindicación 6, en el que los criterios mínimos predeterminados se basan en la relación entre el cuadrado del cambio de la variable de actualización y una varianza de la variable de actualización.
8. El método de la reivindicación 1, en el que el conjunto (d) de datos comprende datos interferométricos generados junto con un proceso de análisis seleccionado del grupo que consiste en síntesis de apertura, radar de apertura sintético interferométrico (IfSAR o InSAR), radar de apertura sintética (SAR) y radar de apertura sintética inversa (ISAR), sonar de apertura sintético, formación de haz y magnetometría de apertura sintética.
- 40 9. El método de la reivindicación 1, en el que el conjunto (d) de datos comprende datos de imagen de resonancia magnética.

10. El método de la reivindicación 1, en el que el conjunto (d) de datos comprende datos de tomografía computarizada o de emisión.
11. El método de la reivindicación 1, en el que el conjunto (d) de datos comprende datos de análisis espectrales.
- 5 12. El método de la reivindicación 1, en el que el conjunto (d) de datos comprende una pluralidad de señales de entrada de diferentes instrumentos, y el modelo de objeto sin ruido comprende una única salida correspondiente a una mezcla de las señales de entrada.
- 10 13. Un medio legible por ordenador no transitorio que incluye software incluido en el mismo, el software incluye instrucciones para hacer que una unidad de procesamiento ejecute una serie de pasos de procesamiento para reconstruir un modelo de objeto a partir de un conjunto (d) de datos obtenido de un proceso físico, en donde el conjunto (d) de datos contiene ruido, los pasos de procesamiento que comprenden:
- recibir el conjunto (d) de datos definido en un espacio de datos;
- construir un modelo de objeto en un espacio de objeto en el que el modelo de objeto comprende una pluralidad de puntos de objeto;
- 15 idear una transformación del modelo de objeto de espacio de objeto a espacio de datos que da como resultado un modelo de datos, en el que la transformación corresponde al proceso físico mediante el cual se obtiene el conjunto (d) de datos;
- seleccionar una función de mérito para determinar un ajuste del modelo de datos al conjunto (d) de datos;
- determinar una variable de actualización del modelo de objetos en el espacio de objetos basado en la función de mérito;
- 20 suavizar la variable de actualización para determinar una variable de actualización suavizada mediante:
- convolucionar la variable de actualización con cada uno de una pluralidad de núcleos de pixon; y
- seleccionar para cada punto de objeto del modelo de objeto un núcleo de pixon que tenga un tamaño mayor que cumpla con un criterio mínimo predeterminado;
- 25 generar un mapa (P) de pixon asignando un índice a cada punto del objeto del modelo de objetos correspondiente al núcleo de pixon seleccionado;
- suavizar de forma iterativa la variable de actualización y actualizar el mapa (P) de pixon y el modelo de objeto en función de la variable de actualización suavizada hasta que se optimice la función de mérito; y
- generar una salida que comprenda un modelo de objeto sustancialmente sin ruido basado en los índices dentro del mapa (P) de pixon actualizado.
- 30 14. El medio legible por ordenador no transitorio de la reivindicación 13, que comprende además instrucciones para hacer que la unidad de procesamiento ejecute el paso de suavizar el modelo de objetos al convolucionar el modelo de objetos en cada punto del objeto con el núcleo de pixon seleccionado según el mapa (P) de pixon.
15. El medio legible por ordenador no transitorio de la reivindicación 13, en el que la función de mérito se optimiza utilizando un método de gradiente conjugado.
- 35 16. El medio legible por ordenador no transitorio de la reivindicación 15, en el que la variable de actualización es un negradiente.
17. El medio legible por ordenador no transitorio de la reivindicación 16, que comprende además la adición de un preacondicionador.
- 40 18. El medio legible por ordenador no transitorio de la reivindicación 13, que comprende además instrucciones para hacer que la unidad de procesamiento ejecute el paso de, después del paso de convolucionar la variable de actualización, restar la variable de actualización para determinar un cambio de variable de actualización.

19. El medio legible por ordenador no transitorio de la reivindicación 18, en el que los criterios mínimos predeterminados se basan en la relación entre el cuadrado del cambio de la variable de actualización y una varianza de la variable de actualización.

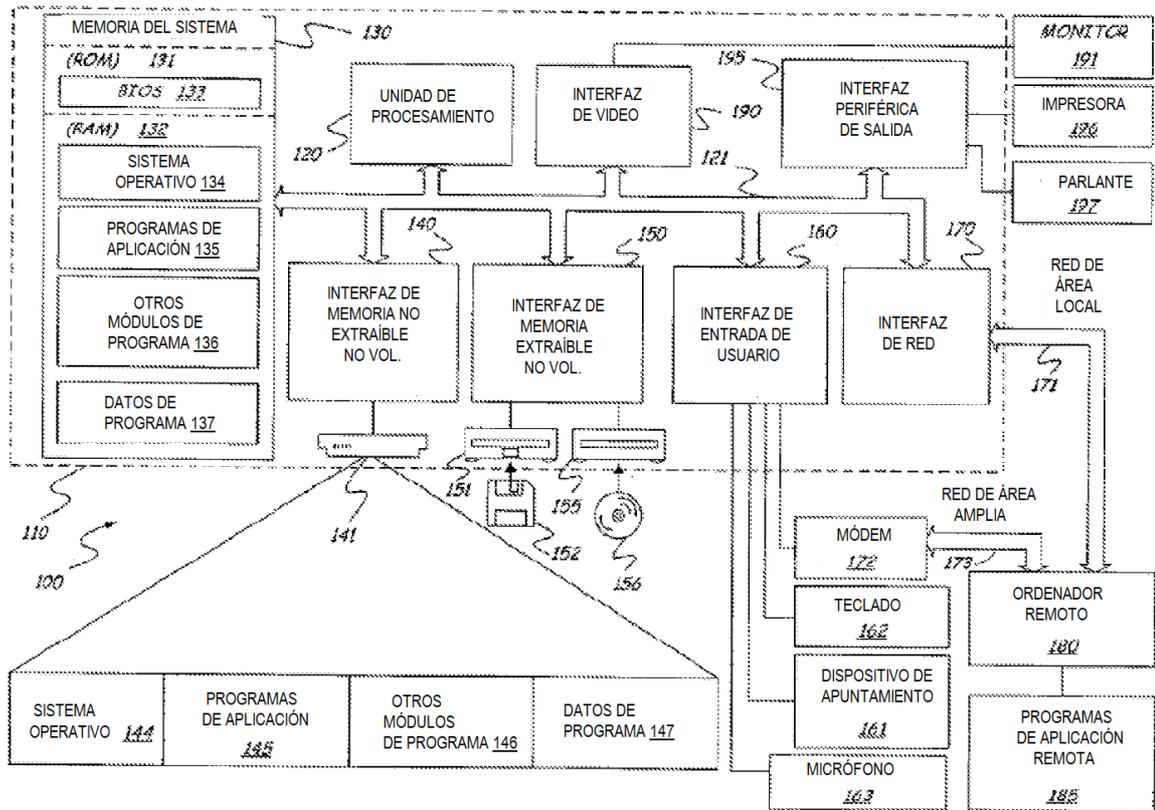


FIG. 1

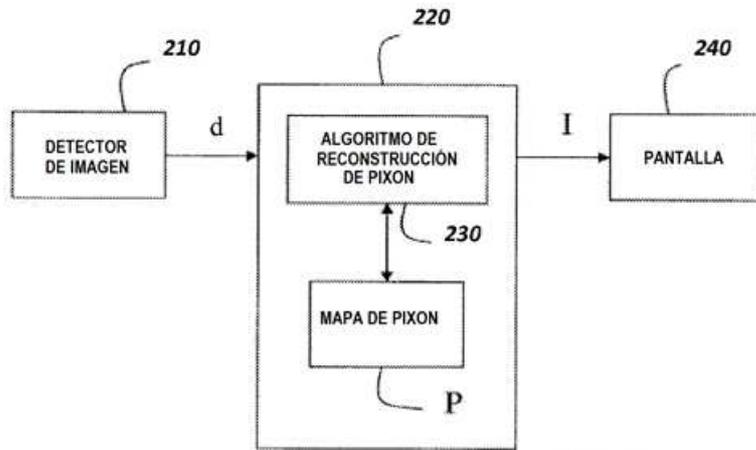


FIG. 2
TÉCNICA ANTERIOR

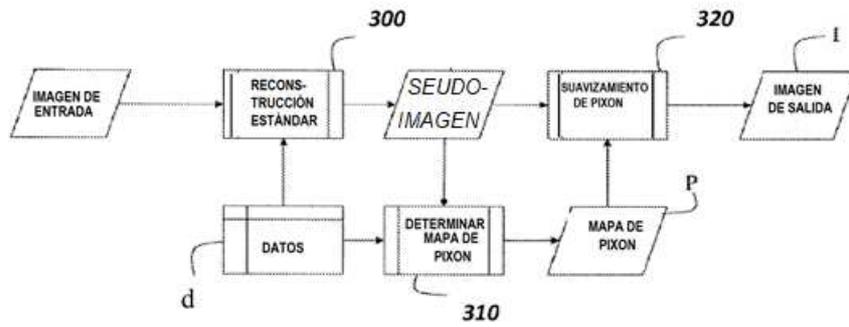


FIG. 3
TÉCNICA ANTERIOR

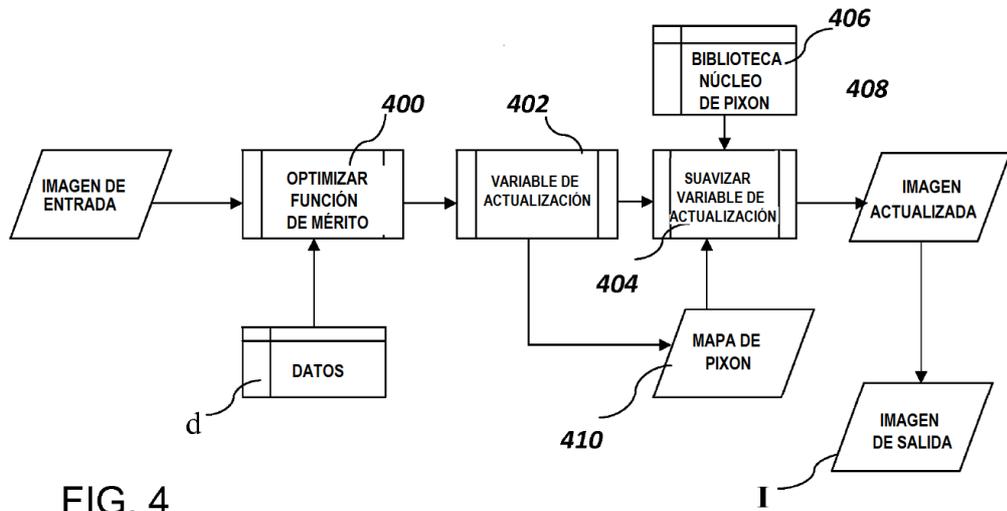


FIG. 4

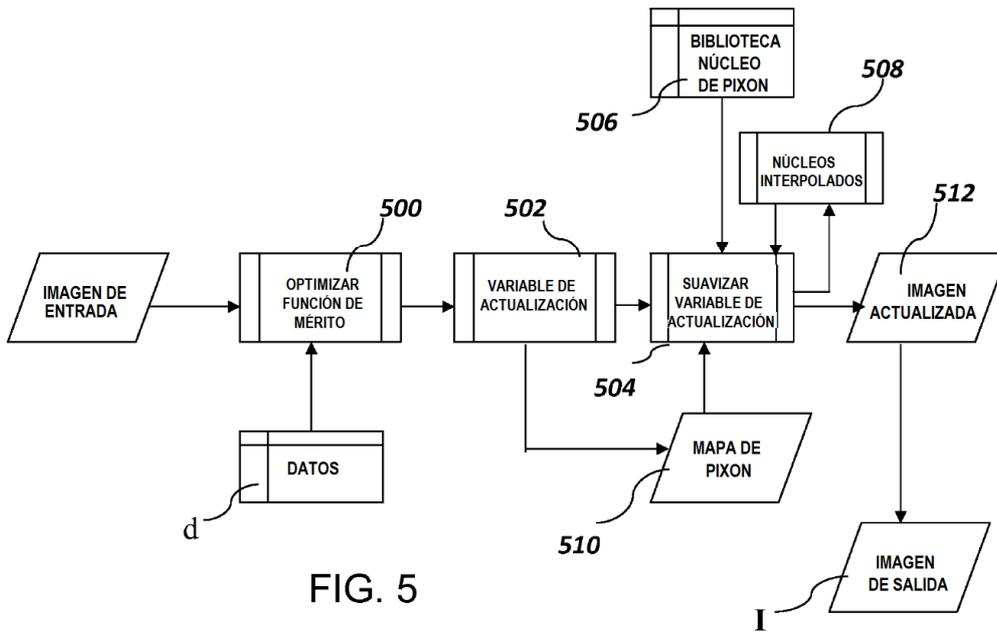


FIG. 5

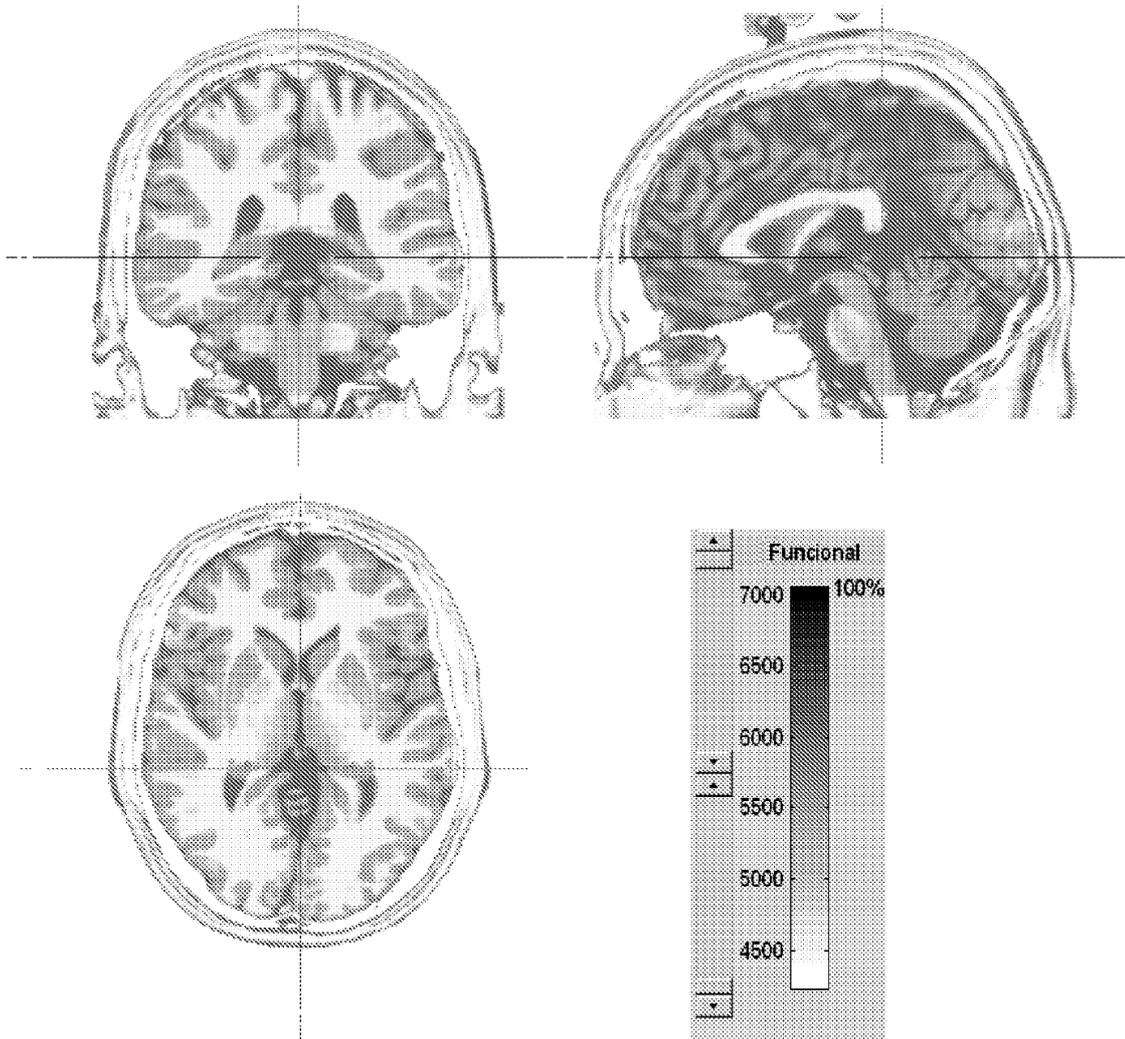


FIG. 6

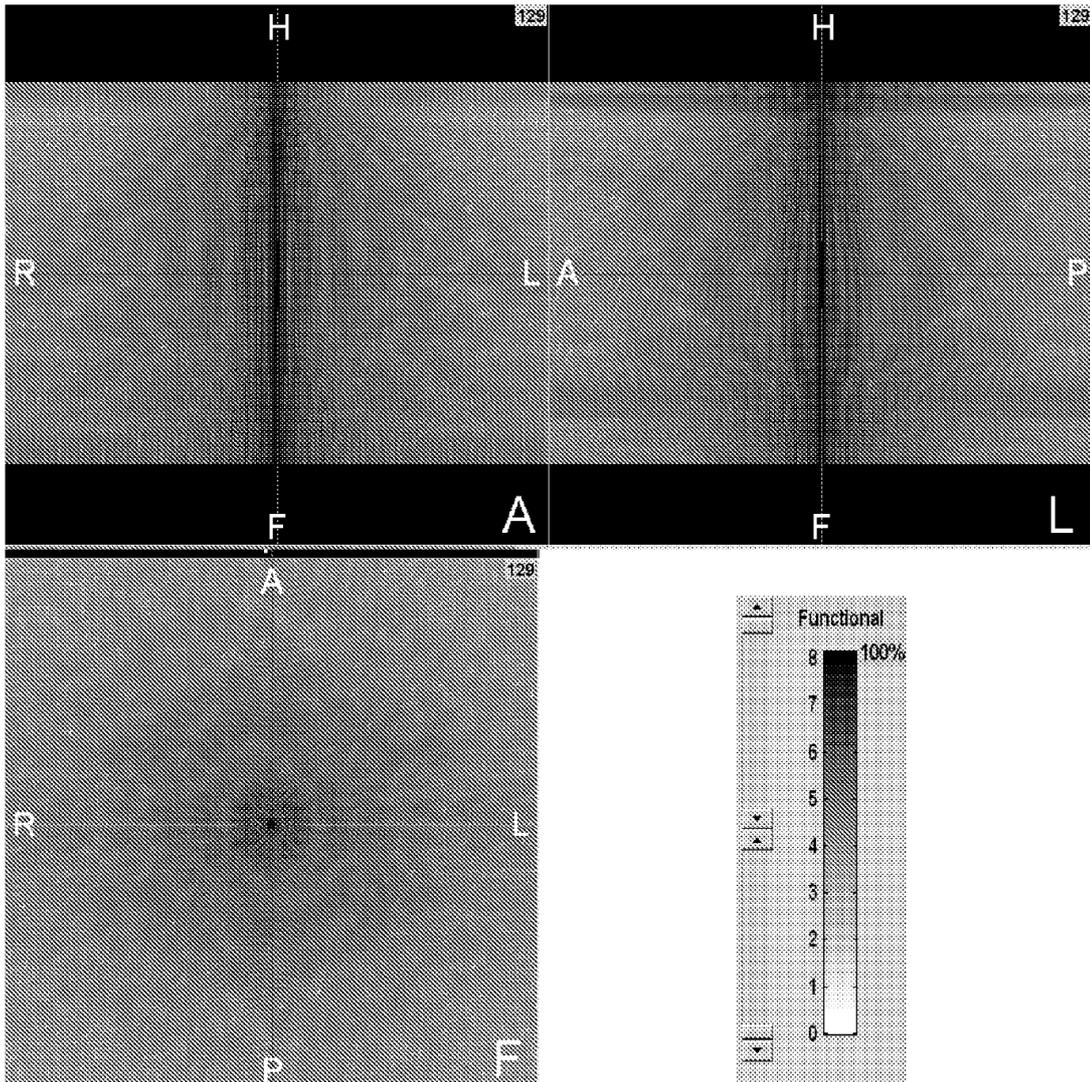


FIG. 7

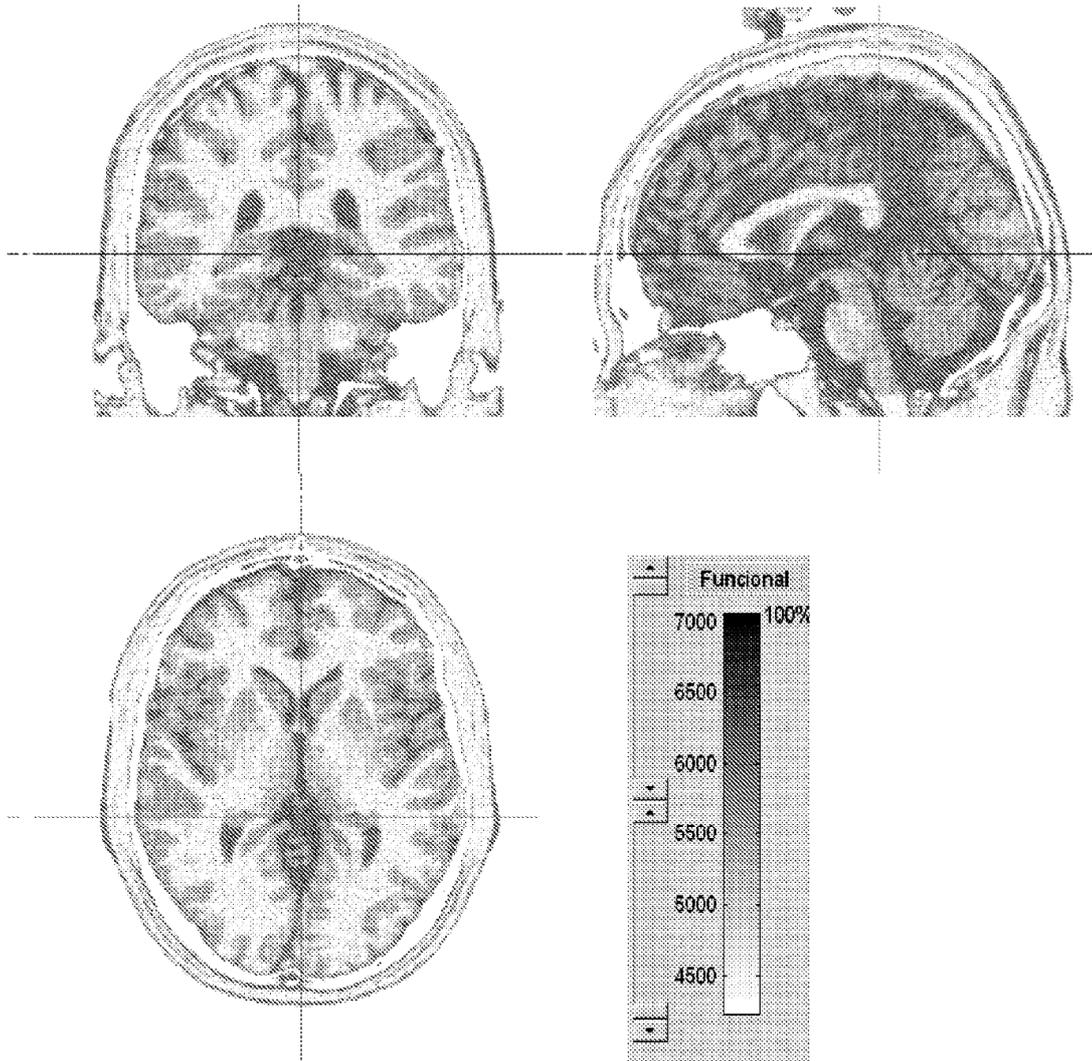


FIG. 8

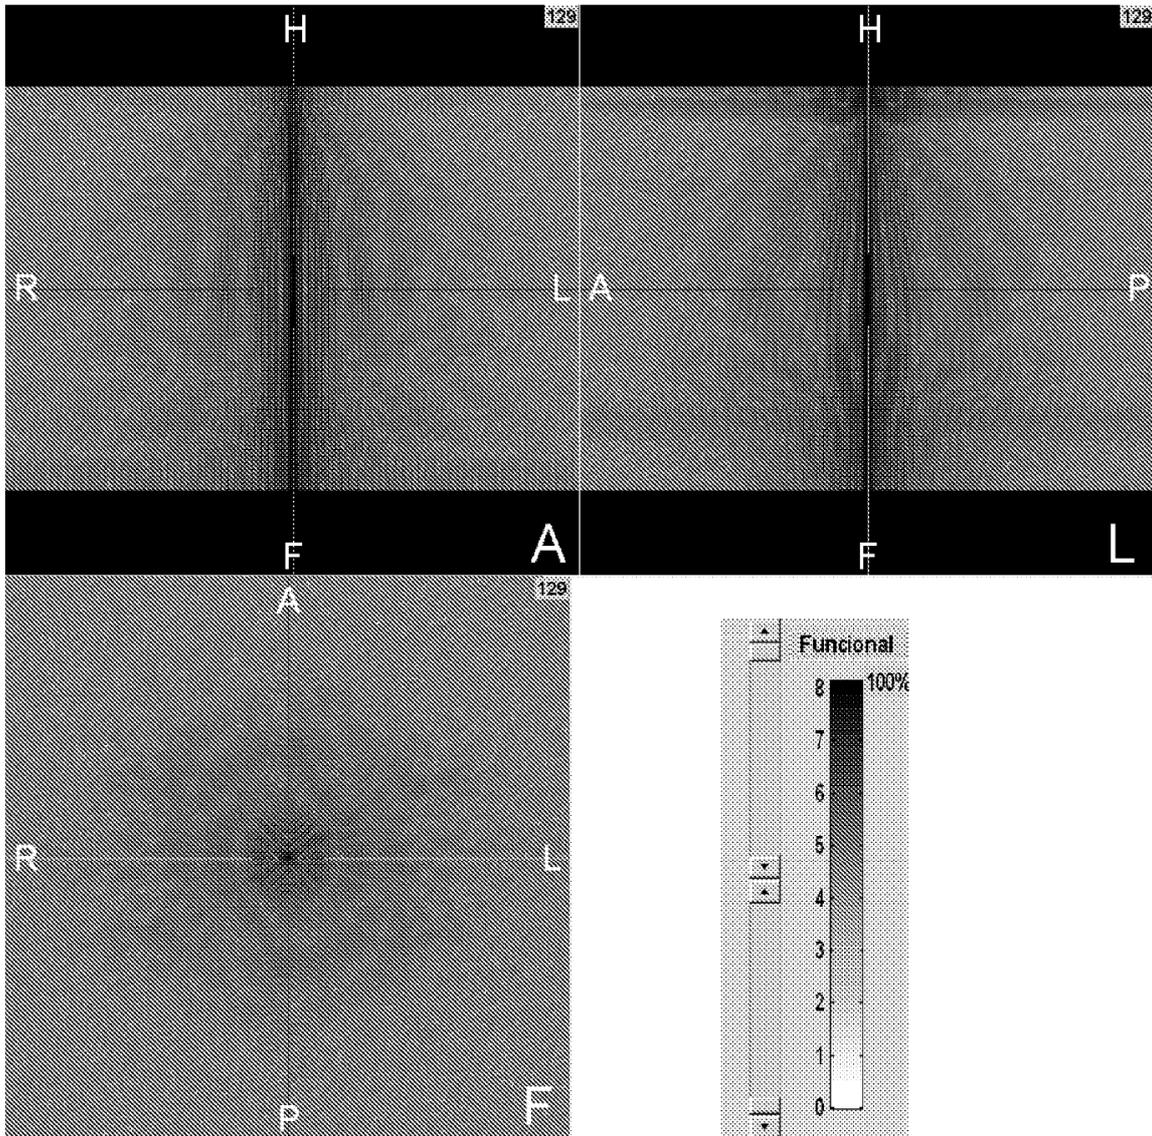


FIG. 9

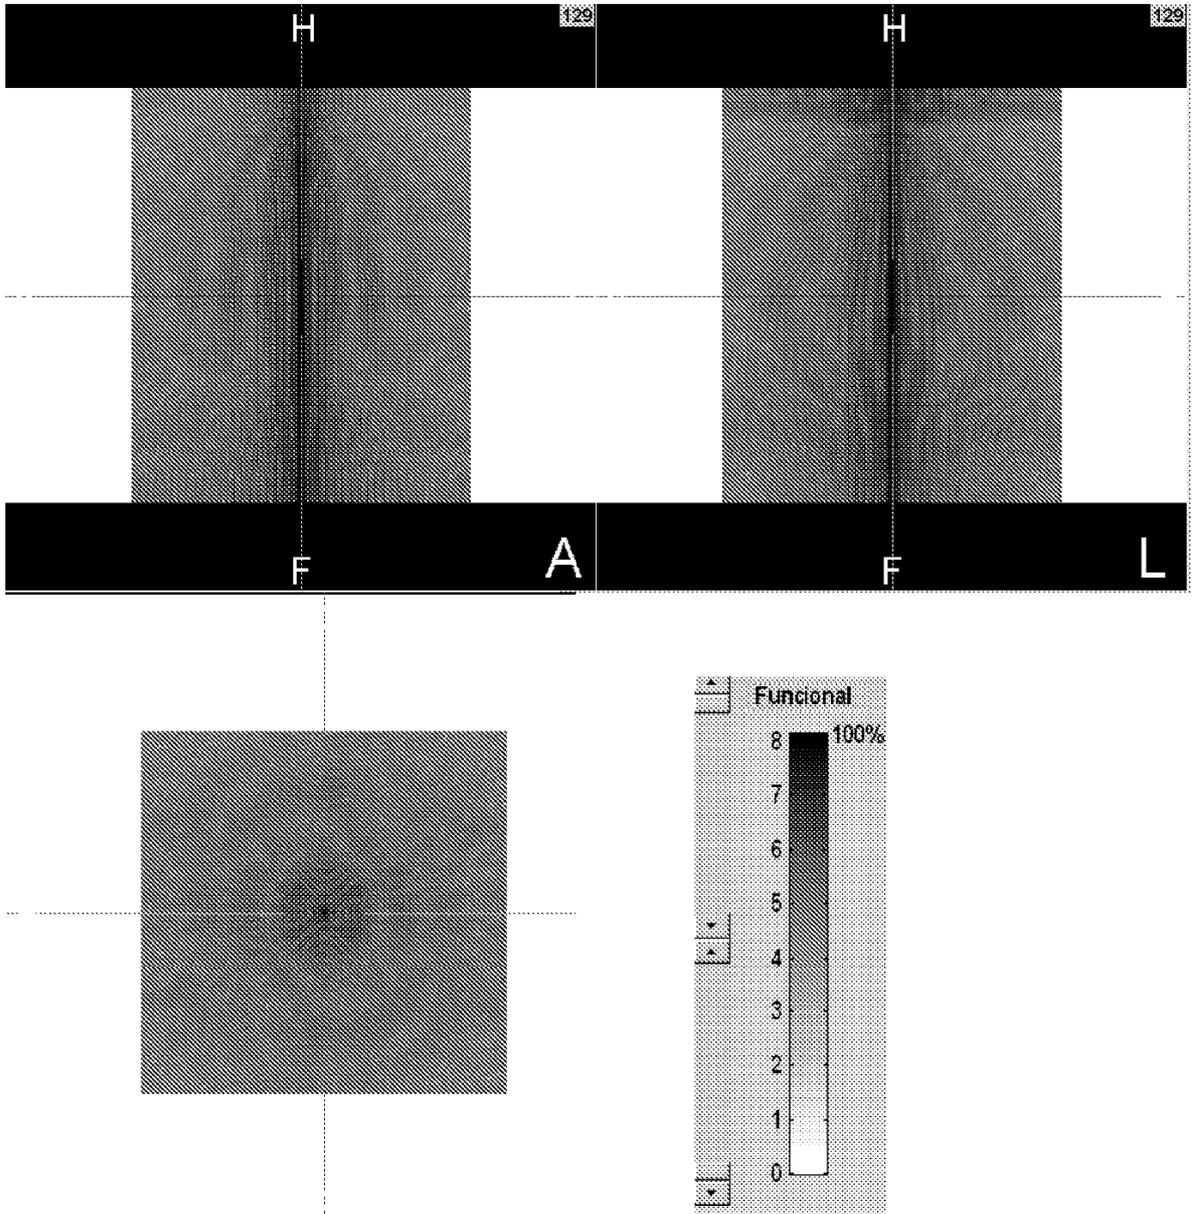


FIG. 10

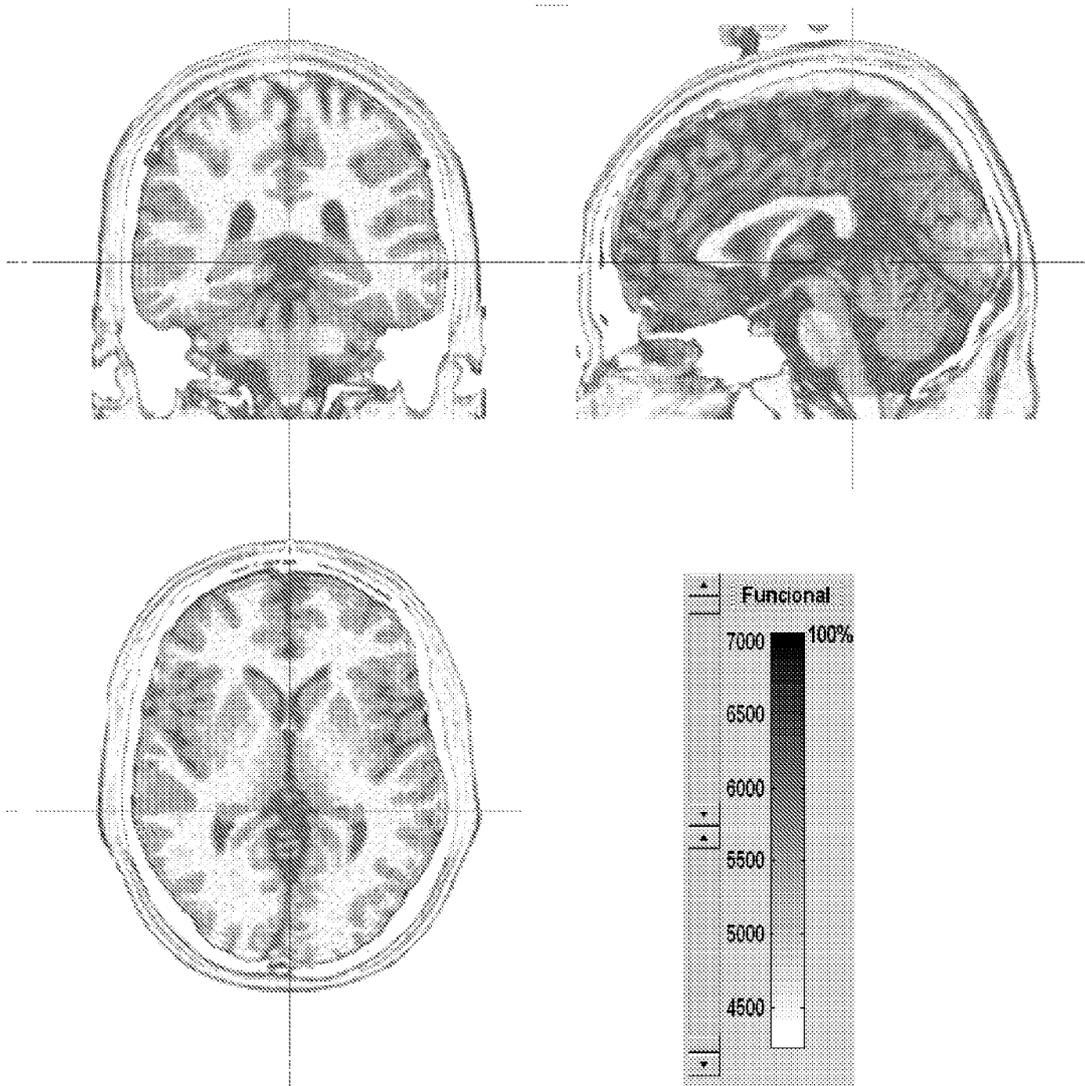


FIG. 11

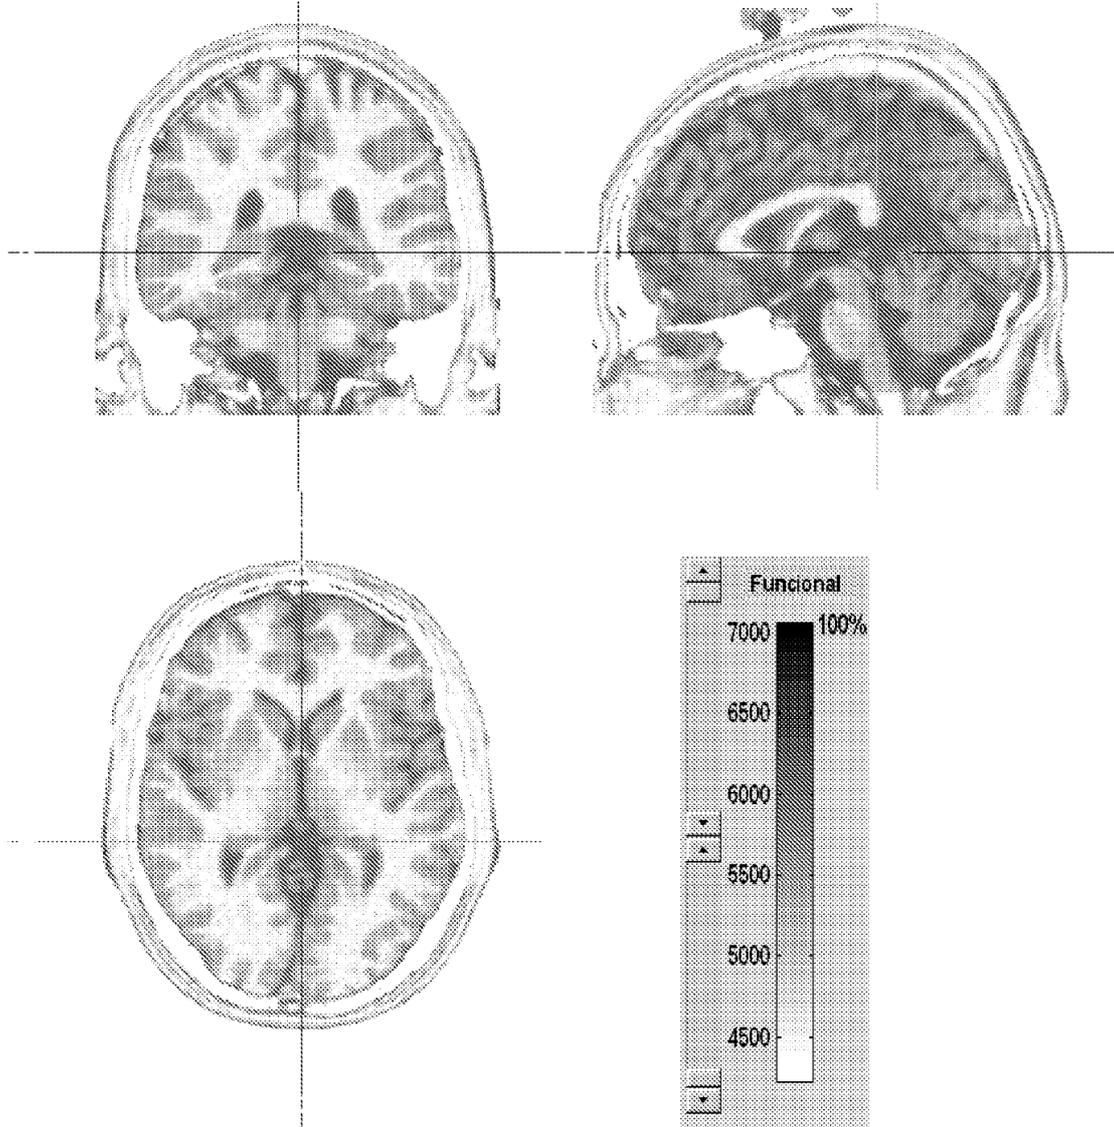


FIG. 12

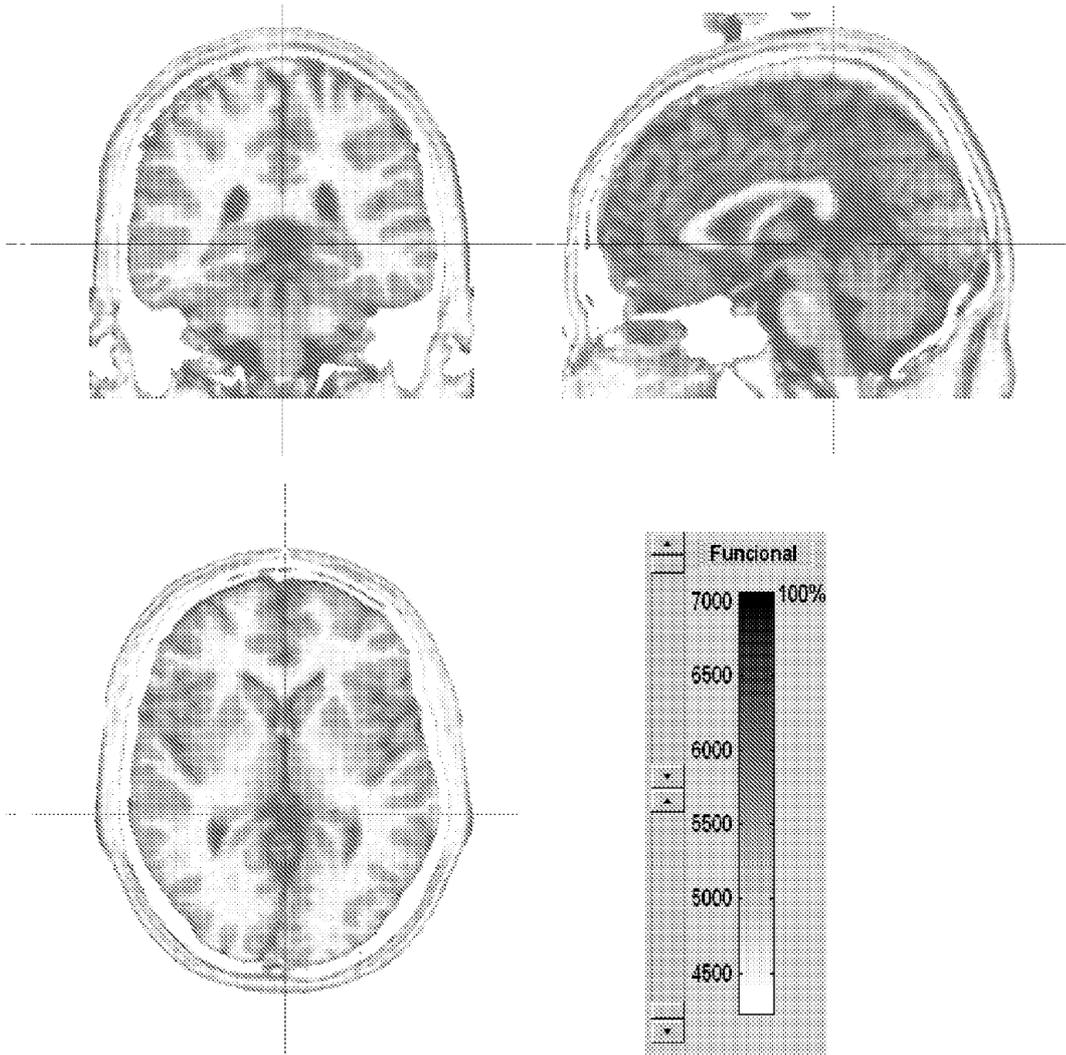


FIG. 13

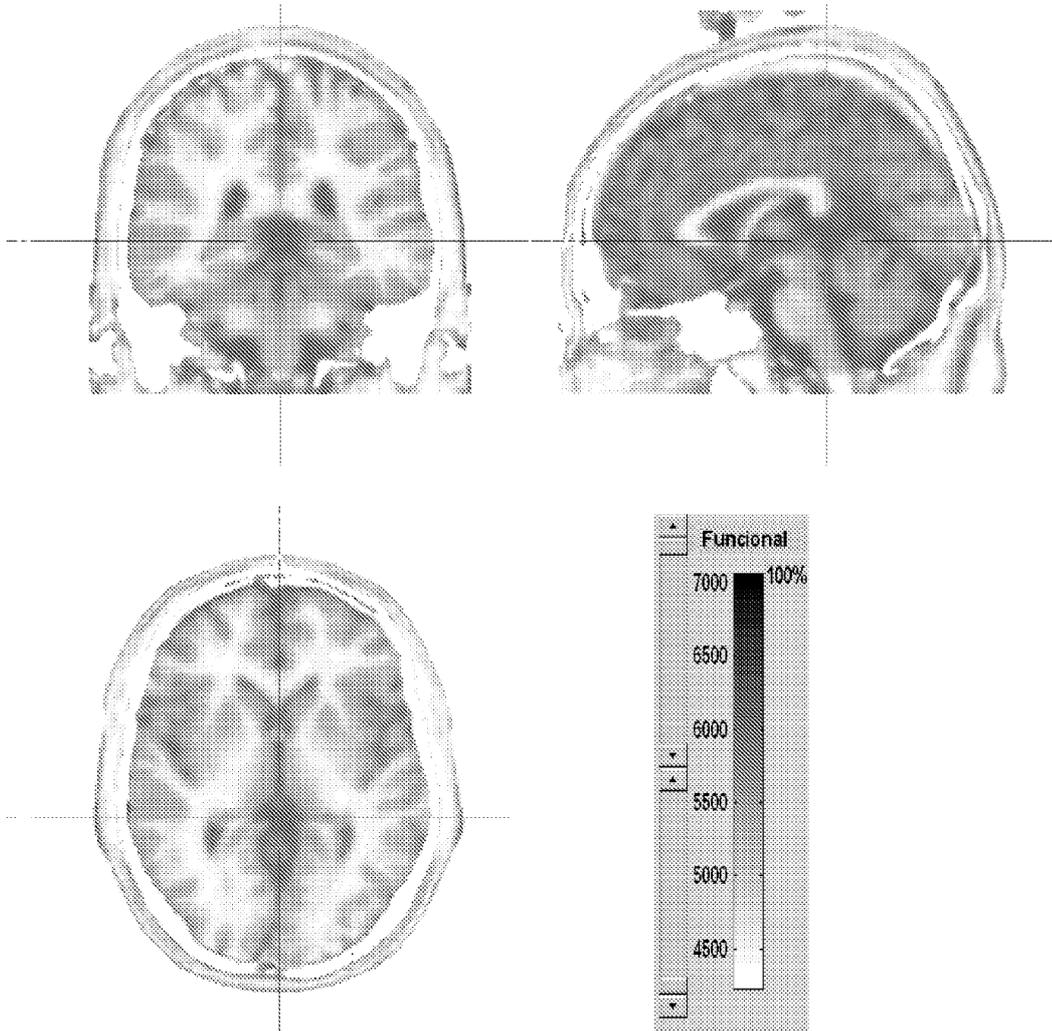


FIG. 14