

19



Industria y Comercio
SUPERINTENDENCIA

SOLICITUD
PATENTE DE INVENCION

21. EXPEDIENTE No.

06-68235

**54. TITULO "GENERACION Y VALIDACION COMPUTARIZADA
DE IMÁGENES DE ENTRENAMIENTO PARA ANALISIS
GEOESTADISTICOS DE PUNTOS
MÚLTIPLES"**

51. CLASIFICACION INTERNACIONAL

7 F05 # 17/60

71. SOLICITANTE

SCHLUMBERGER HOLDINGS LIMITED

DOMICILIO

TORTOLA, ISLAS VIRGENES BRITANICAS

74. REPRESENTANTE LEGAL

ALICIA LLOREDA RICAURTE

T.P. 53.215

72. BOGOTA, D.C.

13 JUL 2006

PETITORIO



SUPERINTENDENCIA DE INDUSTRIA Y COMERCIO
Rad: 06-088235-00000-0000
Fec: 2006-07-13 16:57:48 Dep. 2020 NUECREACIONES
Tra. 2 PATENTES
Eve: 1 REGDEPOSITO
Act 414 DELEGATARIO... Folio: 101

FORMULARIO ÚNICO DE SOLICITUD DE PATENTE.
2000-3

①

SOLICITUD DE:



Patente de Invención.



Patente de Modelo de Utilidad.

②

SOLICITANTE
(71)Nombre: **SCHLUMBERGER HOLDINGS LIMITED**

Dirección: P.O. Box 71, Craigmuir Chambers Road Town, Tortola, Islas Vírgenes Británicas.

Teléfono: 3 264270

Fax: 6 069701

E-mail: jllcco@lloredacamacho.com

Domicilio: Tortola, Islas Vírgenes Británicas.

IDENTIFICACION

C.C. ☐NIT ☐C.E. ☐Otro ☐

Número _____

③

REPRESENTANTE
O APODERADO
(74)Nombre: **ALICIA LLOREDA RICAURTE**

Dirección: Calle 72 No. 5-83 Piso 5, Bogotá, Colombia

Teléfono: 3 264270

Fax: 6 069701

E-mail: jllcco@lloredacamacho.com

IDENTIFICACION

C.C. ☒NIT ☐C.E. ☐Otro ☐Número 39.690.713 TP 53.215

④

INVENTOR(ES)
(72)

Nombre: Piotr MIROWSKI; Daniel TETZLAFF; David McCORMICK; Nneka WILLIAMS y Claude SIGNER.

Dirección: 25 Indian Road, Apt. 1E, New York, New York 10034; 9538 Beverlyhill St., Houston, Texas 77063; 18 Bromfield Road, Acton, Massachusetts 01720; 255 Massachusetts Avenue, Apt. 709, Boston, Massachusetts 02115 y 265 Willow Avenue, Somerville, Massachusetts 02144.

Teléfono: 3 264270

Fax: 6 069701

E-mail: jllcco@lloredacamacho.com

Domicilio: Estados Unidos de América.

IDENTIFICACION

C.C. ☐NIT ☐C.E. ☐Otro ☐

Número _____

⑤

TITULO (54) "GENERACION Y VALIDACION COMPUTARIZADA DE IMÁGENES DE ENTRENAMIENTO PARA ANALISIS GEOESTADISTICOS DE PUNTOS MULTIPLES"

⑥

Clasificación Internacional (51) _____

⑦

Prioridad

SI ☒NO ☐

D. 486

(33) País de Origen

US

(32) Fecha

13-07-05

(31) Número de Solicitud

11/180,191

⑧

Para publicar a partir de la fecha de la presente solicitud a los:

6 meses ☐12 meses ☐18 meses ☐Otro ☐

⑨

Comprobante de pago No. 06-51.757 y 06-52.809Fecha 10-07-06 y 12-07-06

Instrucciones para el diligenciamiento del presente formulario, ver reverso de esta página.

10


ANEXOS

- ☒ Comprobante de pago de la tasa de presentación de la solicitud.
- ☐ Comprobante de pago de la tasa por concepto de excedente de palabras en la publicación.
- ☒ Comprobante de pago por reivindicación de prioridad.
- ☐ Certificado de existencia y representación legal cuando el solicitante sea persona jurídica.
- ☐ Representación legal si fuere el caso
- ☐ Copia certificada de la primera solicitud, si se reivindica prioridad.
- ☐ Traducción simple de la primera solicitud, si se reivindica prioridad.
- ☐ Documento de cesión del inventor al solicitante o a su causante.
- ☒ Descripción de la invención.
- ☒ Una o más reivindicaciones.
- ☒ Dibujos y/o planos necesarios
- ☐ De ser el caso, copia del contrato de acceso.
- ☐ De ser el caso, documento que acredite la licencia o autorización de uso de conocimientos tradicionales de las comunidades indígenas.
- ☐ De ser el caso, certificado de depósito del material biológico
- ☐ Arte final 12x12.

11 FIGURA CARACTERISTICA:

12

NOMBRE: ALICIA LLOREDA RICAURTE

FIRMA: 

C.C. 39.690.713 Usaquén T.P. 53.215

SUPERINTENDENCIA DE INDUSTRIA Y COMERCIO

NIT : 900176089-2

RECIBO OFICIAL DE CAJA : 06 - 51.757
FECHA : JULIO 10 DE 2006

REPÚBLICA DE COLOMBIA - MINISTRO DE INDUSTRIA Y COMERCIO
Rég. 06-068235-00000-0000
Fec: 2006-07-19 16:57:48 Dep. 2020 NUECREACIONES
Tm. 2 PATENTES
Evr. 1 REGDEPOSITO
Act 411 PRESENTACION Folio: 101

***** CONSIGNACION *****

DEPOSITANTE	TIPO PAGO	BANCO	CUENTA	No. PAGO	FECHA PAGO	Vr. PAGO
LLOREDA Y CIA S. A	CONSIGNACION	BANCO POPULAR	050-00110-6	45283971	10/07/2006	4,945.000.00

***** CONCEPTO *****

CANT.	RENTISTICO	CONCEPTO	TOTAL CONCEPTO
1	50005-01-01 SOLICITUDES	1 TRAMITES DE SOL. DE PATENTE DE IN	463,000.00
		TOTAL :	463,000.00

SON: CUATROCIENTOS SESENTA Y TRES MIL PESOS

RESPONSABLE : 
RECIBO DE CAJA APLICADO AL EXPEDIENTE No. _____

2

2

RECIBO DE CAJA APLICADO AL EXPEDIENTE No. _____

ANEXO

Atentamente manifiesto a usted que la fuente normativa de la reciprocidad de la cual se deriva el derecho del solicitante para reivindicar prioridad en el presente caso, se encuentra:

- a) En el Artículo 2 del Anexo 1C, Aspectos de los Derechos de Propiedad Intelectual relacionados con el Comercio, del Acuerdo por el cual se establece la "Organización Mundial de Comercio (OMC)" suscrito en Marruecos el 15 de abril de 1994. Este acuerdo fue aprobado por el Congreso de Colombia mediante Ley 170 de 1994 y por la Corte Constitucional Colombiana mediante Sentencia C-137-95 de 28 de marzo de 1995, y entró en vigencia en nuestro país el 30 de abril de 1995, 30 días después de su ratificación.

Dicho Artículo establece que en lo que respecta a las partes II, III y IV del Acuerdo (referidas a la existencia, alcance y ejercicio de los derechos de propiedad intelectual, entre otros) los Miembros cumplirán los artículos 1 a 12 y el Artículo 19 del Convenio de París --el Artículo que establece la prioridad de las patentes de invención es el Artículo 4--

- b) En el Artículo 4 del mencionado Anexo 1C, Aspectos de los Derechos de Propiedad Intelectual relacionados con el Comercio, del Acuerdo por el cual se establece la Organización Mundial de Comercio (OMC), el cual consagra el "Trato de la nación más favorecida" para los países Miembros del mismo.
- c) En el Artículo 4 del Convenio de París, del cual ya era parte Colombia en el momento en que se presentó la solicitud cuya prioridad ahora reivindico, con lo cual se cumple la reciprocidad exigida en el Artículo 9 de la Decisión 486 del Acuerdo de Cartagena para con solicitudes provenientes del País Miembro del Acuerdo de Cartagena.

GENERACION Y VALIDACION COMPUTARIZADA DE IMÁGENES DE ENTRENAMIENTO PARA ANALISIS GEOESTADISTICOS DE PUNTOS MÚLTIPLES

5

RESUMEN-OBJETO Y FINALIDAD DE LA INVENCION

Un método implementado mediante computadora que de manera automática caracteriza y verifica la estacionaridad de una imagen de entrenamiento para ser utilizada en análisis geoestadísticos de puntos múltiples. La estacionalidad es caracterizada, de preferencia, mediante mediciones estadísticas de la estacionaridad de orientación, la estacionaridad de escala y la estacionaridad de distribución de categorías.

5

GENERACION Y VALIDACION COMPUTARIZADA DE IMÁGENES DE ENTRENAMIENTO PARA ANALISIS GEOESTADISTICOS DE PUNTOS MÚLTIPLES

ANTECEDENTES DE LA INVENCION

Campo de la Invención

[0001] Esta invención se relaciona en lo general con el análisis estadístico de variables aleatorias de un campo de propiedades. En lo particular, esta invención se relaciona con los métodos geoestadísticos de puntos múltiples y las simulaciones.

Estado del Arte

[0002] La geoestadística es una disciplina que se ocupa de las variables aleatorias distribuidas espacialmente (también denominadas "variables regionalizadas"), usualmente aplicadas a problemas de ciencias de la tierra, tales como el cálculo de reservas minerales y la delineación de depósitos minerales, yacimientos de hidrocarburos y acuíferos. La geoestadística de puntos múltiples (MPGS por sus siglas en inglés) se diferencia del resto de las ramas de la geoestadística porque caracteriza la variabilidad espacial empleando patrones (conjuntos de puntos) que contienen más de dos puntos.

[0003] Uno de los objetivos de la geoestadística de puntos múltiples es la simulación, es decir, la generación de valores numéricos a lo largo de una línea, sobre una superficie o en un volumen, de manera que el conjunto de valores determine ciertas propiedades de correlación espacial (por lo general, derivadas de un conjunto de datos denominado "análogo" o "Imagen de entrenamiento") a la vez que, de manera opcional, (en el caso llamado "simulación condicionada") responda a datos predeterminados. En la práctica, el "análogo" puede ser, por ejemplo, el volumen de una roca bien conocida que es estadísticamente similar a un yacimiento petrolífero apenas conocido que

2

está siendo delineado, y los datos que deben ser determinados pueden ser las observaciones de carácter litológico en los pozos o las probabilidades de litologías derivadas de datos sísmicos. De esta manera, las simulaciones de MPGS determinan las limitaciones absolutas o "duras" a partir de los datos adquiridos en los pozos o en los afloramientos, y las limitaciones condicionadas o "suaves" a partir de datos sísmicos, campos de probabilidades facies y cuadrículas de limitaciones de rotación y afinidad (o escala). Tales datos se emplean en un proceso de modelado estocástico para generar mapas unidimensionales (1D), bidimensionales (2D) y/o tridimensionales (3D) de facies geológicas o de propiedades de rocas. Dado que hay un componente aleatorio involucrado en las simulaciones MPGS, las realizaciones individuales de los campos de propiedades creados mediante algoritmos MPGS difieren, pero el conjunto de realizaciones proporcionan a los neocientíficos y a los ingenieros de yacimientos estimaciones cuantitativas mejoradas de la distribución espacial y la incertidumbre de facies geológicas o de propiedades de rocas en un volumen de yacimiento modelado.

[0004] Se ha demostrado recientemente que los métodos geoestadísticos de puntos múltiples son viables computacionalmente u han sido probados en conjuntos de datos reales tal como se señala en (i) Strebel, "Conditional Simulation of complex geological structures using multiple-point statistics", *Mathematical Geology*, v. 34, n. 1, 2002, pp. 1-22; (ii) Strebel y otros, "Modeling of a deepwater turbidite reservoir conditional to seismic data using principal component analysis y multiple-point geostatistics", *SPE Journal*, Vol. 8, No.3, 2003, pp. 227-235; y (iii) Liu y otros, "Multiple-point simulation integrating wells, three-dimensional seismic data, and geology", *American Association of Petroleum Geologists Bulletin* v. 88, no. 7, 2004, pp. 905-921.

[0005] Los métodos geoestadísticos tradicionales se fundamentan en un variograma para describir la continuidad geológica. Sin embargo, un variograma, que viene a ser una medida de dos puntos de variabilidad espacial, no puede describir los patrones reales curvilíneos o geométricamente complejos. Los métodos geoestadísticos de puntos múltiples utilizan una imagen de entrenamiento (en lugar de un variograma) para proporcionar

información geológica. La imagen de entrenamiento suministra una descripción conceptual de la heterogeneidad geológica subterránea, conteniendo posiblemente patrones complejos de puntos múltiples de la heterogeneidad geológica. La simulación mediante estadísticas de puntos múltiples fija estos patrones a los datos de pozo (y/o a los datos del afloramiento) y la información de origen sísmico (y/o a la información del campo de las probabilidades o a cuadrículas de limitaciones).

[0006] Con frecuencia, pero no necesariamente, la imagen de entrenamiento posee una baja resolución (por ejemplo, comúnmente unos cuantos cientos de píxeles en un lado). Cada píxel de la imagen de entrenamiento tiene un nivel (que puede ser un valor binario, un valor de escala de grises o un valor de color) asociado a la misma. El nivel en cada píxel se denomina aquí una categoría. En general hay alrededor de 5 a 10 posibles categorías en cada píxel de la imagen de entrenamiento, pero este número podría ser mayor o menor. Las formas de los elementos geológicos que define la imagen de entrenamiento representan un modelo de los verdaderos elementos geológicos, con cada categoría generalmente representando una facies geológica diferente o un tipo diferente de cuerpo geológico.

[0007] La geoestadística se fundamenta en el bien conocido concepto de las variables aleatorias. En términos sencillos, las propiedades de yacimiento en distintos lugares de una cuadrícula son en gran medida desconocidas o inciertas; por ello cada propiedad de interés en cada lugar de la cuadrícula es convertida en una variable aleatoria cuya variabilidad es descrita por una función de probabilidad. Para llevar a cabo cualquier tipo de simulación geoestadística se requiere una decisión o una presunción de estacionaridad. En los métodos geoestadísticos de puntos múltiples, el uso de imágenes de entrenamiento está limitado por el principio de la estacionaridad, tal como lo señala Caers y otros, "Multiple-point geostatistics: a quantitative vehicle for integrating geologic analogs into multiple reservoir models", AAPG Memoir, Integration of Outcrop and Modern Analogs in Reservoir Modeling, (eds.) Grammer, G.M., 2002. En el caso de modelado 2D y 3D de yacimientos, se dice que una variable aleatoria o un proceso aleatorio es estacionario si la

9

totalidad de sus parámetros estadísticos son independientes de su ubicación en el espacio (no variantes de acuerdo con cualquier traducción). En el caso de las imágenes de entrenamiento, esta estacionaridad puede consistir, pero no estar limitada a:

- una estacionaridad de orientación, donde los elementos direccionales no giran en la imagen de entrenamiento; y
- estacionaridad de escala (donde el tamaño de los elementos en la imagen no cambia en la imagen de entrenamiento).

[0008] Aun cuando en el trabajo de Caers y otros intitulado "Multiple-point geostatistics: a quantitative vehicle for Integrating geologic analogs into multiple reservoir models" se menciona el concepto de estacionaridad, no se presenta una metodología para estimar y validar estadísticamente la estacionaridad de una determinada imagen de entrenamiento que permita asegurar que la imagen de entrenamiento es adecuada para los métodos geoestadísticos de puntos múltiples.

9

[0009] Es por lo tanto un objetivo de la invención proporcionar una metodología para estimar y validar de manera automática la estacionaridad de una determinada imagen de entrenamiento que permita asegurar que la imagen de entrenamiento es adecuada para los métodos geoestadísticos de puntos múltiples.

[0010] Otro objetivo de la invención es proporcionar estructuras de datos que caracterizan las propiedades de una imagen de entrenamiento que pueda ser utilizada en métodos geoestadísticos de puntos múltiples.

[0011] De acuerdo con dichos objetivos, los cuales serán discutidos en detalle más adelante, se proporciona un método implementado por computadora que automáticamente caracteriza y verifica la estacionaridad de una imagen de entrenamiento para ser usada en análisis geoestadísticos de puntos múltiples. De preferencia, la estacionaridad de la imagen de entrenamiento es caracterizada mediante mediciones estadísticas de la estacionaridad de orientación, la estacionaridad de escala y la estacionaridad de distribución de categorías.

[0012] Se podrá apreciar que los métodos os de la presente invención permiten determinar de manera automática y precisa si una imagen de entrenamiento es o no es estacionaria y, por tanto, adecuada para las realizaciones MPGS que requieren de imágenes de entrenamiento estacionarias. En consecuencia, los geólogos que utilizan los métodos implementados por computadora de la presente invención ahorran tiempo y evitan realizaciones MPGS innecesarias por usar imágenes de entrenamiento inadecuadas.

[0013] De acuerdo con la realización preferida de la invención, las mediciones estadísticas que caracterizan la estacionaridad de orientación de la imagen de entrenamiento incluyen, por lo menos, uno de los siguientes: (i) un primer conjunto de estadísticas que caracteriza la no uniformidad del campo de

11

orientación y, por ende, ofrece un indicio de que hay una o varias direcciones preferenciales en la cuadrícula de orientación, (ii) un segundo conjunto de estadísticas que caracteriza la normalidad de la distribución de direcciones en la cuadrícula de orientación y, por ende, ofrece un indicio de que hay una dirección dominante en el campo de orientación, y (iii) un tercer conjunto de estadísticas que caracteriza la repetibilidad del campo de orientación, lo cual ofrece un indicio de que el campo de orientación es similar en diferentes zonas de la imagen. Las mediciones estadísticas que caracterizan la estacionaridad de escala de la imagen de entrenamiento de preferencia incluyen las distancias entre un primer conjunto de vectores de características y un segundo conjunto de vectores de características. El primer conjunto de vectores de características se deriva de un primer conjunto de imágenes de desplazamientos que se generan al someter la imagen a una serie de operaciones de muestreo que dependen de la rotación. El segundo conjunto de vectores de características proviene de un segundo conjunto de imágenes de desplazamientos que se generan al someter un patrón de referencia seleccionado de la imagen a una serie de operaciones de muestreo que dependen de la rotación y de la escala.

[0014] Los objetivos y ventajas adicionales de la invención serán evidentes a quienes dominan la materia al leer la descripción detallada junto con la Figuras que le acompañan.

BREVE DESCRIPCION DE LAS ILUSTRACIONES

[0015] La FIG. 1(A) es un diagrama en bloques de un sistema de procesamiento computarizado que representa la metodología de la presente invención.

[0016] La FIG. 1(B) es un flujograma que muestra el flujo de trabajo de la metodología computarizada para la generación y verificación automática de imágenes de entrenamiento y el subsiguiente análisis geoestadístico de puntos múltiples basado en dichas imágenes según la presente invención.

12

[0017] Las FIGS. 2(A) - 2(E) son una secuencia de imágenes que ilustran las operaciones de procesamiento de imágenes realizadas en una imagen candidata como parte del flujo de trabajo de la FIG. 1(B); en este ejemplo, la imagen candidata es una fotografía aérea a color del delta de un río.

[0018] Las FIGS. 3(A) – 3(D) son una secuencia de imágenes que ilustran las operaciones de procesamiento de imágenes que obtienen un campo de orientación para una categoría de imágenes de entrenamiento como parte del flujo de trabajo de la FIG. 1(B); la FIG. 3(A) corresponde a la imagen de entrenamiento; la FIG. 3(B) es una imagen que muestra el componente Y del campo de gradiente 2D que se genera al aplicar el filtro Prewitt G_y a la categoría de imágenes de entrenamiento de la FIG. 3(A); la FIG. 3(C) es una imagen que muestra el componente X del campo de gradiente 2D que se genera al aplicar el filtro Prewitt G_x a la categoría de imágenes de entrenamiento representativa de la FIG. 3(A); y la FIG. 3(D) es una imagen que muestra el campo de orientación de la categoría de imágenes de entrenamiento de la FIG. 3(A).

[0019] La FIG. 4 es un flujograma que ilustra las operaciones que generan las estadísticas de estacionaridad de orientación y un puntaje basado en éstas como parte del flujo de trabajo de la FIG. 1(B).

[0020] Las FIGS. 5(A) y 5(B) son gráficos que ilustran la función de probabilidad-densidad de una distribución Von Mises.

[0021] Las FIGS. 6(A) - 6(I) son diagramas que muestran la segmentación de una categoría de imágenes de entrenamiento en zonas superpuestas; estas zonas superpuestas son utilizadas para calcular las estadísticas de estacionaridad de orientación (y un puntaje basado en las mismas), las estadísticas de estacionaridad de escala (y un puntaje basado en las mismas), y las estadísticas de estacionaridad de distribución de categorías (y un puntaje basado en las mismas) como parte del flujo de trabajo de la FIG. 1(B).

[0022] La FIG. 7 es un flujograma que ilustra las operaciones que generan las estadísticas de estacionaridad de escala y un puntaje basado en éstas como parte del flujo de trabajo de la FIG. 1(B).

[0023] La FIG. 8 es un gráfico que ilustra un sistema de muestreo de vecindad circular de cuarto orden.

[0024] La FIG. 9 es un gráfico que ilustra un sistema de muestreo de adyacencia circular de cuarto orden adaptado para el muestreo dependiente de la rotación y la escala; el muestreo dependiente de la rotación y la escala se emplea para muestrear la imagen de entrenamiento y extraer los vectores de características de dicha imagen de entrenamiento; el muestreo dependiente de la rotación y la escala se emplea para muestrear un patrón de referencia y extraer los vectores de características de dicho patrón de referencia; estos vectores de características son analizados para generar estadísticas de estacionaridad de escala y un puntaje basado en éstas como parte del flujo de trabajo de la FIG. 1(B).

[0025] Las FIGS. 10(A) – 10(Y) son diagramas que muestran un conjunto de 25 parejas de factores de afinidad las cuales se utilizan para calcular las estadísticas de estacionaridad de escala y un puntaje basado en éstas como parte del flujo de trabajo de la FIG. 1(B).

[0026] La FIG. 11 es un diagrama esquemático que ilustra las operaciones que calculan las estadísticas de estacionaridad de escala y un mapa de afinidad basado en éstas como parte del flujo de trabajo de la FIG. 1(B).

[0027] La FIG. 12(A) es un ejemplo de imagen de entrenamiento, la cual se obtiene copiando y pegando la esquina superior izquierda (delineada por un rectángulo) en las demás partes de la imagen con distintas transformaciones de afinidad aplicadas a las mismas.

[0028] La FIG. 12(B) es un conjunto de mapas de afinidad que ilustran la distancia entre los vectores de características para las partes correspondientes de la imagen de entrenamiento y el patrón de referencia sobre distintas parejas de factores de afinidad para la imagen de entrenamiento de la FIG 12(A) con la esquina superior izquierda seleccionada como patrón de referencia; los píxeles de cada imagen bidimensional están en escala de grises, estando las distancias representadas por los píxeles cuantificados en un rango de valores en escala de grises.

[0029] La FIG. 12(C) es un conjunto de mapas de afinidad que ilustran la distancia entre los vectores de características para las partes correspondientes de la imagen de entrenamiento y el patrón de referencia sobre distintas parejas de factores de afinidad para la imagen de entrenamiento de la FIG 12(A) con la esquina superior izquierda seleccionada como patrón de referencia; los píxeles de cada imagen bidimensional son binarios, estando las distancias representadas por los píxeles asignados a un rango binario de valores; las distancias más cercanas son asignadas a un valor binario (es decir, negro), en tanto que las demás distancias son asignadas al otro valor binario (es decir, blanco).

[0030] La FIG. 13 es un gráfico que muestra la medición de una dispersión de puntos en un espacio bidimensional; esta medición se utiliza para calcular las estadísticas de estacionaridad de escala y un puntaje basado en éstas como parte del flujo de trabajo de la FIG. 1(B).

[0031] La FIG. 14 es un diagrama que ilustra un plano tridimensional de los puntajes estacionarios correspondientes a un número de imágenes de entrenamiento; los ejes corresponden a tres medidas diferentes de estacionaridad donde eje X corresponde a la medida de la estacionaridad de distribución de categorías, el eje Y corresponde a la medida de la estacionaridad de escala, y el eje Z corresponde a la medida de la estacionaridad de orientación; puede decirse que las regiones de este espacio tridimensional delimitan "buenas" imágenes de entrenamiento y que pueden ser utilizadas como criterio de decisión para verificar automáticamente si una

imagen de entrenamiento en particular es suficientemente estacionarias para ser utilizada en análisis geoestadísticos de puntos múltiples que exijan dicha estacionaridad.

[0032] La FIG. 15 es un diagrama esquemático que ilustra el método SNESIM de análisis geoestadístico y simulación.

[0033] La FIG. 16(A) es un diagrama esquemático que ilustra el método SIMPAT de análisis geoestadístico y simulación.

[0034] La FIG. 16(B) es un diagrama esquemático que ilustra una extensión del método SIMPAT que emplea geoestadísticas basadas en de características.

DESCRIPCION DETALLADA DE LA MATERIALIZACION PREFERIDA

[0035] La FIG. 1(A) es un diagrama funcional de bloques que muestra un sistema computarizado de propósitos generales 100 que materializa la presente invención. El sistema computarizado 10 puede comprender una estación de trabajo (o una computadora personal de alto desempeño) que realice los cálculos pertinentes y la lógica de decisiones que se indican más adelante, tales como el procesamiento de imágenes de entrenamiento, la generación y evaluación de estadísticas de estacionaridad de las imágenes de entrenamiento y el análisis estadístico de puntos múltiples basado en las mismas. Por ejemplo, el sistema computarizado 10 puede incluir un dispositivo de visualización 12 y dispositivos de ingreso de datos por parte del usuario tales como un teclado 14 y un ratón 16. El sistema computarizado 10 también incluye una memoria 18 (una memoria persistente como una unidad de disco duro magnético así como una memoria no persistente tal como uno o más módulos DRAM) que almacene las aplicaciones de software que se ejecutan en un procesador 20 a fin de realizar los cálculos pertinentes y la lógica de decisiones que se indican más adelante, tales como el procesamiento de imágenes de entrenamiento, la generación y evaluación de estadísticas de

16

estacionaridad de las imágenes de entrenamiento y el análisis estadístico de puntos múltiples basado en las mismas. Las aplicaciones de software, que comprenden una secuencia programada de instrucciones y datos, generalmente se encuentran almacenadas en uno o más discos ópticos que son cargados a la memoria 18 mediante una unidad de disco óptica (no aparece en la ilustración) para su almacenaje permanente en la misma. Como alternativa, las aplicaciones de software pueden ser cargadas a la memoria 18 a través de una conexión en red (por ejemplo, una conexión a Internet) u otro medio adecuado para su almacenaje permanente en la misma. En la presente descripción, la "imagen" se refiere en forma indistinta a una línea o una superficie o un volumen, y consiste en un conjunto contiguo de píxeles iguales, cada uno de los cuales podrá contener un valor (o un número).

[0036] LA FIG. 1(B) muestra un flujo de trabajo que representa la metodología computarizada para la generación y validación automática de imágenes de entrenamiento y simulaciones geoestadísticas de puntos múltiples basados en éstas de acuerdo con la presente invención. Las imágenes candidatas que se emplean para la generación de imágenes de entrenamiento se almacenan en una base de datos de imágenes 101 lo cual puede realizarse mediante cualquier tipo de almacenamiento electrónico, óptico o magnético. En el bloque 103, se importa una imagen candidata desde la base de datos de imágenes 101. En este punto, la imagen candidata puede ser una imagen de cualquier tipo en blanco y negro, en escala de grises, en color o multiespectral y tener cualquier definición (resolución). Para simplificar la descripción, se identificará a la imagen candidata como una imagen de "alta resolución" en el bloque 105.

[0037] En el bloque 107, la imagen candidata del bloque 105 es procesada para ajustar el número de categorías de los píxeles de la imagen, si así se desea, y para ajustar su resolución, si así se desea. Los típicos métodos geoestadísticos de puntos múltiples requieren una imagen de entrenamiento con un pequeño número de categorías, por ejemplo, menos de 11. Con frecuencia las dimensiones de la imagen de entrenamiento deben ser un pequeño número de píxeles por lado. La labor de reducir el número de niveles

de escala de grises/color de la imagen candidata y a la vez mantener la importancia geológica de las categorías asignadas de la imagen candidata es de dificultad variable y depende de la complejidad y la calidad de la imagen candidata, incluyendo la presencia de ruido y efectos de iluminación. La lista de operaciones para procesamiento de imágenes que se pueden utilizar como parte de este paso incluye pero no se limita a las operaciones de morfología matemática en imágenes, fijación de umbrales o conglomeración de histogramas en color o en escala de grises y filtrado de imágenes a paso alto o a paso bajo. A menudo, el resultado deseado solo puede lograrse mediante una combinación de operaciones sucesivas de procesamiento de imágenes lo que permite al usuario interconectar estos bloques, visualizar las interconexiones mediante un gráfico y luego guardar el flujo de trabajo interconectado del procesamiento de imágenes para uso posterior. La imagen resultante generada por el flujo de trabajo del procesamiento de imágenes del bloque 107 es identificado como una imagen de entrenamiento de "baja resolución y poca categoría" en el bloque 109. Las dimensiones y categorías de la imagen de entrenamiento del bloque 109 concuerdan con las dimensiones y categorías requeridas para los subsiguientes métodos geoestadísticos de puntos múltiples.

[0038] Las FIGS. 2(A) – 2(E) ilustran un ejemplo del flujo de trabajo del procesamiento de imágenes del bloque 107 en una imagen candidata que es una fotografía aérea a color. FIG. 2(A) es una copia en escala de grises de la fotografía aérea a color. La FIG 2(B) es el resultado de la eliminación del efecto de iluminación de la imagen de la FIG. 2(A) por la aplicación de una operación morfológica. La FIG. 2(C) es el resultado de una segmentación de colores de la imagen de la FIG 2(B) y de la eliminación de grandes áreas conectadas (en este caso, el río y el mar) mediante una técnica de llenado de regiones (*flood-fill*). En la FIG 2(D), se ha retenido solamente el nivel de escala de grises correspondiente a los ríos, y los otros dos niveles de escala de grises han sido fusionados en uno. La FIG 2(E) es una sección resaltada de la imagen de la FIG 2(D) y muestra el patrón del canal del río que se retiene para fines de una imagen de entrenamiento candidata para los métodos geoestadísticos de puntos múltiples. Este patrón tiene 2 categorías, el río y el trasfondo.

[0039] En el bloque 111, se calcula la estacionaridad de la imagen de entrenamiento del bloque 109. Las operaciones derivan estadísticas estacionarias que caracterizan la estacionaridad de la imagen de entrenamiento. De preferencia, estas estadísticas caracterizan la estacionaridad del campo de orientación (bloque 111A), la estacionaridad de escala de la imagen (bloque 111B) y la estacionaridad de la distribución de categorías (bloque 111C) para la imagen de entrenamiento del bloque 109.

[0040] En el bloque 113, las estadísticas estacionarias derivadas en el bloque 111 son analizadas a fin de determinar si la imagen de entrenamiento del bloque 109 satisface una serie de limitaciones predeterminadas que establecen si la imagen de entrenamiento debe o no debe ser utilizada en subsiguientes análisis geoestadísticos de puntos múltiples (es decir, el bloque 119). Si las estadísticas estacionarias satisfacen las limitaciones predeterminadas, la imagen de entrenamiento se añade a una base de datos de imágenes de entrenamiento 115 lo cual puede realizarse mediante cualquier tipo de almacenamiento electrónico, óptico o magnético. Se puede obtener la imagen de entrenamiento desde la base de datos 115 (u obtenerla directamente del bloque 103) para utilizarla en un análisis geoestadístico de puntos múltiples (bloque 119). Estas operaciones pueden implicar el formateo de la imagen de entrenamiento como una cuadrícula de imagen de entrenamiento (bloque 117) de acuerdo con el formato que sea necesario para el análisis geoestadístico de puntos múltiples (bloque 119).

[0041] Si se determina en el bloque 113 que las estadísticas estacionarias no satisfacen las limitaciones predeterminadas, el usuario decide si la imagen de entrenamiento no estacionaria debe o no debe ser incorporada a la base de datos de imágenes de entrenamiento 115 (bloque 121) o si se le descarta (bloque 123). Se puede obtener la imagen de entrenamiento no estacionaria desde la base de datos 115 (u obtenerla directamente del bloque 121) para utilizarla en un análisis geoestadístico de puntos múltiples (bloque 127). Estas operaciones pueden utilizar una imagen de entrenamiento no estacionaria como base para una cuadrícula de imagen de entrenamiento

no estacionaria (bloques 125A, 127A), una cuadrícula de limitaciones de escala (bloques 125B, 127B) o una cuadrícula de limitaciones de orientación (bloques 125C, 127C).

[0042] Para las imágenes no estacionarias (es decir, aquellas no descartadas en el bloque 123), las operaciones pueden retrocederse hasta el bloque 107 donde pueden aplicarse diferentes técnicas de procesamiento de imágenes para extraer otras características de la imagen candidata del bloque 105 a fin de producir una imagen de entrenamiento que cumpla los criterios de estacionariedad (bloques 109-113).

[0043] La FIG. 4 ilustra las operaciones del bloque 111A que caracteriza la estacionariedad del campo de orientación de la imagen de entrenamiento del bloque 109. Se asume que por cada imagen de entrenamiento, las categorías de la imagen de entrenamiento se corresponden con diferentes elementos geológicos. Con el fin de separar las estadísticas de estacionariedad de orientación por categorías y por tipo de elemento geológico, se aísla cada categoría y el campo de orientación y las estadísticas derivadas de éste son derivadas para la categoría en particular. Para aislar una categoría en particular, los píxeles que provienen de otra categoría son todos asignados a la misma categoría de fondo. Las estadísticas de estacionariedad por categoría pueden entonces ser promediadas o ponderadas de acuerdo con la importancia que el usuario desee atribuirles.

[0044] Las operaciones sobre la imagen de entrenamiento (bloque etiquetado 401) comienzan con la inicialización de un contador (variable "K") a 1 (bloque 403) y luego transformando una copia de la imagen de entrenamiento de modo que la categoría correspondiente al contador k (es decir, la k^{ma} categoría) es aislada de las demás categorías (bloque 405). Esta imagen es identificada más adelante como una "categoría de imagen de entrenamiento".

[0045] En los bloques 407 y 409, el campo de orientación para la categoría de imagen de entrenamiento es derivado. En la realización preferida, el campo de orientación se calcula computando primero el campo del gradiente

de la categoría de imagen de entrenamiento empleando una convolución bidimensional, tal como los filtros "verticales" y "horizontales" de Prewitt, y luego extrayendo el primer componente principal del campo del gradiente sobre una ventana deslizante de tamaño fijo (a la cual se le identifica como el "núcleo") utilizando el análisis de componentes principales. Este análisis es descrito en detalle en la tesis presentada por Feng X, "Analysis and Approaches to Image Local Orientation Estimation" para obtener el título de Master en Ciencias en Ingeniería de la Computación de la Universidad de California en Santa Cruz, 2003, y en el trabajo de Randen y otros, "Three-Dimensional Textura Attributes for Seismic Data Analysis", Schlumberger Stavanger Research, SEG 2000 Expanded Abstracts, 2000, incorporados en su totalidad aquí por referencia. El filtro "vertical" de Prewitt

$$G_y = \begin{bmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{bmatrix} \text{ enfatiza los bordes "horizontales" (es decir, los bordes$$

"horizontales" (es decir, los bordes a lo largo de la dirección X). El filtro

$$\text{"horizontal" de Prewitt } G_x = \begin{bmatrix} 1 & 0 & -1 \\ 1 & 0 & -1 \\ 1 & 0 & -1 \end{bmatrix} \text{ enfatiza los bordes "verticales"}$$

(es decir, los bordes a lo largo de la dirección Y).

[0046] El campo del gradiente está conformado por un vector bidimensional por cada pixel de la categoría de imagen de entrenamiento. Empleando el análisis de componente principal, el primer componente principal del campo del gradiente se extrae de una máscara circular escaneada de la imagen. Esto es similar a calcular los eigenvectores y los eigenvalores de la

matriz $T = \frac{1}{n} \sum_{i=1}^n x_i x_i^T$. Se obtiene la máscara circular de una ventana

cuadrada (núcleo) de tamaño fijo N donde a los píxeles se les da un peso $W(x,y)$ como en la ventana gaussiana bidimensional $W(x,y)$ donde

$$W(x,y) = e^{-\frac{1}{2} \left[\left(\frac{x - \frac{N}{2}}{\frac{N}{2}} \right)^2 + \left(\frac{y - \frac{N}{2}}{\frac{N}{2}} \right)^2 \right]}, \text{ donde } 0 \leq x < N \text{ y } 0 \leq y < N$$

21

[0047] El análisis del componente principal genera dos atributos: (i) el vector principal unitario $V / \|V\|$ (ya sea como un valor en radianes o como componentes x e y); y (ii) su valor principal asociado s_1 , el cual es también el módulo de vector principal y que realza las fuertes tendencias isotrópicas. Debe notarse que siendo los vectores del gradiente ortogonales hacia la orientación deseada de la imagen, la dirección principal debe ser rotada en $\pi/2$ radianes. El campo de orientación se define por el vector principal unitario y su valor principal asociado (o magnitud) a intervalos fijos, con valores típicos de 64 píxeles para el tamaño del núcleo o máscara y de 16 píxeles para el espaciado de dos muestras consecutivas. El campo de orientación se puede representar ya sea mediante el ángulo y la magnitud de los vectores principales unitarios (donde todos los ángulos son computados con módulos de 180 grados) o por los componentes X e Y de los vectores principales unitarios y sus valores principales asociados.

[0048] Las FIGS. 3(A) – 3(D) son una secuencia de imágenes que ilustran las operaciones de procesamiento de imágenes que extraen un campo de orientación para una categoría de imagen de entrenamiento como parte del flujo de trabajo de la FIG. 1(B). La FIG. 3(A) es un ejemplo de categoría de imagen de entrenamiento. La FIG. 3(B) ilustra el componente T del campo bidimensional del gradiente que se genera al aplicar el filtro Prewitt G_y a la categoría de imagen de entrenamiento de la FIG. 3(A). El componente principal de los vectores de orientación puede computarse en ventanas superpuestas deslizantes muestreadas con regularidad (también denominadas "núcleo de orientación"). La FIG. 3(D) muestra el campo de orientación donde el núcleo de orientación tiene un tamaño de 64×64 píxeles y en muestreado cada 16 píxeles.

[0049] Volviendo a la FIG.4, en el bloque 411, el campo de orientación generado en el bloque 409 se utiliza para derivar estadísticas que caracterizan la orientación axial de la categoría de imagen de entrenamiento y uno o más puntajes asociados a las mismas. De preferencia, estas estadísticas son

parámetros de distribución que estiman la distribución de Von Mises del campo de orientación y el (los) puntaje(s) asociados a éste que caracterizan uno o más de lo siguiente: (i) la uniformidad/no uniformidad de la distribución de datos circulares del campo de orientación, la cual provee una indicación de que hay una o varias direcciones preferenciales en la imagen; (ii) la normalidad de la distribución de datos circulares de la categoría de imagen de entrenamiento, la cual provee una indicación de que hay una dirección dominante del campo de orientación, y (iii) la repetibilidad del campo de orientación, la cual provee una indicación de que el campo de orientación es similar a lo largo de diferentes zonas de la imagen.

[0050] En el bloque 413 se determina si el contador "k" corresponde a la última categoría (K) de la imagen de entrenamiento. De no ser así, el contador "k" se incrementa por uno (es decir, $k = k + 1$) en el bloque 415 y las operaciones retoman al bloque 405 para aislar la siguiente categoría de la imagen de entrenamiento y computar las estadísticas de estacionaridad de orientación para la siguiente categoría (bloques 407-411). Cuando la última categoría ha sido procesada ($k = K$ en el bloque 413), las operaciones continúan hasta el bloque 417 para mostrar los resultados del procesamiento de estacionaridad de orientación de los bloques 407-411 para cada categoría de la imagen de entrenamiento. Las estadísticas de estacionaridad por categoría pueden ser entonces promediadas o ponderadas de acuerdo con la importancia que el usuario desee atribuirles para posterior procesamiento y toma de decisiones.

[0051] En la realización preferida, se asume que el campo de orientación sigue una distribución normal circular. En este caso, los ángulos de los vectores de orientación de módulo de 180 grados son importantes y las magnitudes de dichos vectores son irrelevantes. De este modo, la distribución debe tener una simetría axial. Por supuesto, la hipótesis de la normalidad es restrictiva pero se puede justificar por el hecho de que el campo de orientación es computado con núcleos grandes. Esto ofrece una hipótesis de una distribución doble de Von Mises, la cual se describe en detalle en Mardia, "Statistics of Discretional Data", Academic Press, New York, 1972, pp. 57-69,

incorporado en su totalidad aquí por referencia. La distribución de Von Mises es controlada por dos parámetros, el parámetro de escala κ y el parámetro de ubicación μ , y sigue la siguiente función de densidad de probabilidades (FDP)

$$f(\theta, \mu, \kappa) = \frac{1}{2\pi I_0(\kappa)} e^{\kappa \cos(2(\theta - \mu))} \text{ como se observa en las FIGS. 5(A) y 5(B).}$$

La variable κ es la concentración (una medida inversa de la "difusión" del ángulo de orientación θ) y la variable μ es su dirección media. La función $I_0(\kappa)$

es la función Bessel de orden cero definida por $I_0(\kappa) = \frac{1}{2\pi} \int_0^{2\pi} e^{\kappa \cos \theta} d\theta$. La

distribución de Von Mises es, por naturaleza, unimodal a menos que la concentración κ sea igual a 0 cuando se hace uniforme. Todas las estadísticas y pruebas relativas a la distribución de Von Mises pueden obtenerse multiplicando los ángulos por 2. La distribución simple de Von Mises si-

gue la función de densidad de probabilidades $f(\theta, \mu, \kappa) = \frac{1}{2\pi I_0(\kappa)} e^{\kappa \cos(\theta - \mu)}$.

[0052] Asumiendo un campo de orientación unimodal normalmente distribuido, se utilizan preferiblemente las siguientes fórmulas para obtener un $\bar{\mu}$ estimado del μ medio circular:

$$C = \frac{1}{n} \sum_{i=1}^n \cos(2\theta_i)$$

$$S = \frac{1}{n} \sum_{i=1}^n \sin(2\theta_i)$$

$$R = \sqrt{C^2 + S^2}$$

$$\tilde{u} = \text{signo}(S) \times \frac{\cos^{-1}\left(\frac{R}{C}\right)}{C}$$

Donde C y S son los cosenos y senos de dirección, y R se define como la longitud media resultante y está directamente relacionada con la concentración κ . Estas ecuaciones aparecen descritas en detalle en Rock, "Lecture Notes in Earth Sciences 18 – Numerical Geology", Springer Verlag, 1988, incorporado en su totalidad aquí por referencia. Obsérvese que los ángulos están duplicados de antemano y por ello deben ser divididos entre dos al final. Se puede derivar un estimado κ de la máxima estimación de probabilidad. Como alternativa, se puede derivar el estimado κ utilizando la siguiente aproximación

$$\kappa = \begin{cases} \frac{R}{6} (12 + 6R^2 + 5R^4) & \text{si } R < 0.65 \\ \frac{1}{2(1-R) - (1-R)^2 - (1-R)^3} & \text{si } R \geq 0.65 \end{cases}$$

[0053] La estimación de la estacionaridad de orientación de la categoría de imagen de entrenamiento requiere un análisis que determine si la distribución de los vectores del campo de orientación es auto-similar en diferentes regiones de la categoría de imagen de entrenamiento. Por este motivo, se realizan pruebas de no uniformidad y normalidad en toda la imagen y en cada una de varias zonas superpuestas. En el ejemplo ilustrado por las FIGS. 6(A) – 6(I), la categoría de imagen de entrenamiento se particiona en 9 zonas superpuestas, las cuales son marcadas como Z1, Z2, ... Z9. En esta configuración hay $1 + 9 = 10$ pruebas diferentes. Con el fin de probar una imagen para estacionaridad de orientación, se definen empíricamente tres (3) factores: (i) la no uniformidad del campo de orientación que provee una indicación de que hay una o varias direcciones preferenciales en el campo de orientación, (ii) la normalidad de la distribución de direcciones en el campo de orientación, la cual provee una indicación de que hay una dirección dominante en el campo de orientación, y (iii) la repetibilidad del campo de orientación, la

cual provee una indicación de que el campo de orientación es similar a lo largo de diferentes zonas de la imagen. La prueba de repetibilidad consiste en comparar las estadísticas de orientación tomadas de todas las parejas de

zonas. Utilizando la 9 zonas que se señalan en las FIGS. 6(A) – 6(I), existen C_9^2 = 36 combinaciones de esas parejas.

[0054] La no uniformidad de la distribución de datos circulares del campo de orientación se estima con una prueba de Rayleigh basada en el valor de la longitud media resultante R antes descrita con las dos siguientes hipótesis: (i) H_{A0} : hipótesis nula de uniformidad, es decir, el campo de orientación no tiene una dirección preferencial y podría haber sido extraída de una distribución aleatoria; y (ii) H_{A1} : la no uniformidad de la distribución de datos circulares del campo de orientación. Para los valores pequeños de $N \leq 100$, la prueba sencillamente es $R > K$ y los valores críticos para $Pr(R > R_0) = \alpha$ con los siguientes niveles de confianza $\alpha \in \{0.10, 0.05, 0.025, 0.01, 0.001\}$ basados en tablas y preferiblemente derivados de la tabla que se muestra en la página 300 de Mardia, "Statistics of Directional Data", Academic Press, New York, 1972. Para $N > 100$, la prueba se basa en: $2NR^2 > K$, donde $2NR^2$ se distribuye como χ^2_2 . Los valores críticos para $\alpha \in \{0.10, 0.05, 0.025, 0.01, 0.001\}$ son $\chi^2_{2, \alpha} \in \{4.605, 5.991, 7.378, 9.21, 13.816\}$. Como resultado de esta prueba, se vuelve al valor del nivel de confianza α que produce el valor crítico más cercano al valor probado. El porcentaje de certeza para la no uniformidad se da entonces como $1 - \alpha$. Todas las 9 zonas y todo el campo de orientación son probados para determinar la presencia de uniformidad. El puntaje final para la no uniformidad correspondiente a toda la imagen en una determinada escala (o tamaño del núcleo de orientación) es:

$$no\ uniformidad = \frac{(1 - \alpha_{imagen}) + \sum_{k=1}^9 (1 - \alpha_{z_k})}{10}$$

[0055] La principal limitación de esta prueba de Raleigh es su hipótesis de normalidad de la distribución circular que permite la computación de R , el cual es la longitud media resultante en la que se basa la estadística de la prueba. Por tanto, si la distribución tiene, por ejemplo, dos modos obvios que se encuentran 40-60 grados aparte, la prueba podría dar una alta probabilidad de no uniformidad debido a un valor relativamente alto de R . En consecuencia, esta prueba no puede ser considerada como una prueba que evalúa la hipótesis de la uniformidad versus la no uniformidad. Un enfoque preferido es establecer el puntaje de no uniformidad de una determinada zona en cero si no se puede realizar la prueba por ausencia de normalidad de la distribución de esa zona.

[0056] La normalidad de la distribución de datos circulares del campo de orientación se estima con una prueba de bondad de ajuste que determina la presunción de que la distribución de Von Mises es correcta y, por ende, confirma una distribución normal que posee una dirección preferencial (en teoría unimodal de acuerdo con su FDP) o que puede hacerse uniforme para un valor extremo de $R = 0^* / ^*$. Esta prueba plantea dos hipótesis: (i) H_{B0} : hipótesis nula de bondad de ajuste con la distribución doble de Von Mises (es decir, la normalidad de la distribución); y (ii) H_{B1} : no hay una distribución de Von Mises (es decir, no hay una distribución normal). Se puede emplear una prueba clásica de ji cuadrado de bondad de ajuste mediante la comparación del histograma circular $\{O_i\}_{i \in [1,18]}$, del campo de orientación medido con el histograma teórico $\{E_i\}_{i \in [1,18]}$ que vendría dado por una distribución doble de Von Mises con la misma dirección media estimada μ y el parámetro de concentración κ y computado sobre los mismos bins $\theta_{i \in [1,18]}$. Los datos axiales medidos se encuentran entre [-90, 90 grados] y son empaquetados en 18 bins de $\{O_i\}_{i \in [1,18]}$ de ancho 10 grados que tienen los siguientes centros de bin:

$$\theta_{i \in [1,18]} = \{-85, -75, -65, -55, -45, -35, -25, -15, -5, 5, 15, 25, 35, 45, 55, 65, 75, 85\}$$

$$\forall i \in [1,18], E_i = f(\theta_i, \mu, \kappa) = \frac{1}{2\pi I_0(\kappa)} e^{\kappa \cos(2(\theta_i - \mu))}$$

18

26

26

El criterio de la prueba es $\chi^2 > \chi_{\nu, \alpha}^2$ donde $\chi^2 = 3 \sum_{i=1}^n \frac{(O_i - E_i)^2}{E_i}$

27

la prueba de ji cuadrado, se emplea $\nu = 18 - 2 - 1 = 15$ grados de libertad (estamos comparando histogramas de 18 bins y la distribución de Von Mises tiene 2 parámetros, la ubicación y la escala). Los valores críticos para

$\alpha \in \{0.995, 0.99, 0.975, 0.95, 0.90, 0.75, 0.50, 0.25, 0.10, 0.05, 0.025, 0.01, 0.005\}$ son $\chi_{15}^2 \in \{4.60, 5.23, 6.26, 7.26, 8.55, 11.04, 14.34, 18.25, 22.31, 25.00, 27.49, 30.58, 32.80\}$.

Como resultado de la prueba, se vuelve al valor del nivel de confianza α que produce el valor crítico más cercano al valor probado. Todas las 9 zonas y todo el campo de orientación son probados para determinar la presencia de uniformidad. El puntaje final para la normalidad correspondiente a toda la imagen en una determinada escala (o tamaño del núcleo de orientación) es:

$$normalidad = \frac{\alpha_{imagen} + 3 \sum_{k=1}^9 \alpha_{z_k}}{10}$$

[0057] La prueba de ji cuadrado de bondad de ajuste tiene limitaciones debido al binning de los datos circulares en un histograma, limitaciones que se hacen más evidentes cuando el valor de la concentración estimada se hace muy elevado. En ese caso, la prueba podría arrojar un nivel de confianza muy bajo o nulo para la prueba de normalidad por cuanto los datos son obviamente unimodales. En consecuencia, se pueden establecer dos condiciones que automáticamente produzcan un nivel de confianza $\alpha = 100\%$, es decir, (i) > 20 ; y (ii) $card(\{O_i\}_{0[1,18]}) > 0) < 3$. También se obtiene la corrección de un artefacto numérico debido al binning - o sea, que por un bin dado i , un valor muy pequeño de la observación estimada $0 < E_i \ll 1$ y una observación real $O_i = 1$ (con el número total de observaciones siendo relativamente alto) aportarán un número grande a la estadística de la prueba χ^2 , haciendo que en consecuencia la prueba falle. En vista de que un binning inadecuado contribuye

28

considerablemente a este resultado, la contribución de esta observación real en particular a la prueba χ^2 puede establecerse en cero.

28

[0058] La repetibilidad de la distribución del campo de orientación se estima con una prueba de dos partes. La primera prueba es una prueba no paramétrica que compara dos distribuciones tomadas de dos zonas de la imagen. La prueba emplea dos hipótesis: (i) H_{C0} : hipótesis nula de tener dos muestras de la misma población (distribución); y (ii) H_{C1} : las dos muestras no son de la misma distribución. Aquí, las dos muestras que respectivamente contienen las observaciones n_1 y n_2 , donde $N = n_1 + n_2$. Ambas muestras son combinadas y luego ordenadas. Los conjuntos $\{a_i\}_{i=1, \dots, N}$ y $\{b_j\}_{j=1, \dots, N}$ se definen de la siguiente manera. El conjunto $\{a_i\}_{i=1, \dots, N}$ está conformado por los números de las observaciones provenientes de la primera muestra entre las primeras estadísticas de orden i de la muestra combinada. El conjunto $\{b_j\}_{j=1, \dots, N}$ está conformado por los números de las observaciones provenientes de la segunda muestra entre las primeras estadísticas de orden j de la muestra combinada. Se calcula un valor U^2 de la siguiente manera:

$$U^2_{n_1, n_2} = \frac{n_1 n_2}{N^2} \sum_{k=1}^N 3 (d_k - \bar{d})^2$$

$$d_k = \frac{b_k}{n_2} - \frac{a_k}{n_1}$$

$$\bar{d} = \frac{1}{N} \sum_{k=1}^N d_k$$

Los valores críticos de $U^2_{n_1, n_2}$ para los niveles de confianza de $\forall 0 \{10\%, 5\%, 2.5\%, 1\%, 0.1\%\}$ aparecen dados en la página 314 de Mardia, "Statistics of Directional Data", Academic Press, New York, 1972. Los detalles de esta prueba U^2 de Watson de dos muestras se describen en Mardia, "Statistics of

28

[0059] Con frecuencia la prueba U^2 de dos muestras falla cuando la dispersión de direcciones es muy estrecha, probablemente debido a que las direcciones no están intercaladas en forma regular. Como una alternativa que también es sensible a distribuciones muy estrechas de los ángulos $\{\theta_i\}_{i \in [1, n_1]}$ y $\{\theta_j\}_{j \in [1, n_2]}$, se puede utilizar la siguiente prueba:

si $([\text{rango}(\{\theta_i\}_{i \in [1, n_1]}) < 40^\circ] \text{ y } [\text{rango}(\{\theta_j\}_{j \in [1, n_2]}) < 40^\circ])$

$$V = \begin{cases} 0 & \text{si } ([\min(\{\theta_i\}_{i \in [1, n_1]}) < \min(\{\theta_j\}_{j \in [1, n_2]})] \text{ y } [\max(\{\theta_i\}_{i \in [1, n_1]}) < \min(\{\theta_j\}_{j \in [1, n_2]})]) \\ 0 & \text{si } ([\min(\{\theta_j\}_{j \in [1, n_2]}) < \min(\{\theta_i\}_{i \in [1, n_1]})] \text{ y } [\max(\{\theta_j\}_{j \in [1, n_2]}) < \min(\{\theta_i\}_{i \in [1, n_1]})]) \\ 1 & \text{de otro modo} \end{cases}$$

además

ejecutar la prueba no paramétrica U^2 de Watson

terminar si

Una vez que la prueba se ha ejecutado para todos los pares de zonas $C_g^2 = 36$

Posibles, la primera parte del puntaje de repetibilidad se computa de la siguiente manera:

$$\text{repetibilidad} = \frac{\sum_{i \in [1, n_1]} \sum_{j \in [1, n_2]} V_{z_i z_j}}{C_g^2}$$

[0060] La segunda prueba que estima la repetibilidad de la distribución del campo de orientación es una prueba paramétrica que compara dos distribuciones tomadas de dos zonas de la imagen bajo la presunción de que ambas distribuciones son Von Mises. La primera parte de esta prueba

paramétrica es una prueba de igual concentración con un nivel de confianza V_α .

3°

En esta primera parte, para $\bar{R} < 0.45$, la estadística

$$Z = \frac{\frac{2}{\sqrt{3}} [\phi(\bar{R}_1) - \phi(\bar{R}_2)]}{\sqrt{\frac{1}{n_1-4} + \frac{1}{n_2-4}}} \quad (\text{donde } \phi(\bar{R}) = \sin^{-1} \left\{ \min \left\{ \sqrt{\frac{2\bar{R}}{3}}, 1 \right\} \right\})$$

se computa y compara con la desviación normal convencional. En lugar de buscar valores críticos en las tablas, se calcula el nivel de confianza a partir de la estadística Z utilizando la función de distribución normal acumulativa

$$D(Z) = \frac{1 + \operatorname{erf} \left[\frac{Z}{\sqrt{2}} \right]}{2} \cdot \text{Dado que la región crítica consiste en extremos}$$

en extremos iguales, el nivel de confianza se obtiene escribiendo

$V_\alpha = 1 - 2 \times |D(Z) - 0.5|$. Para $0.45 \leq \bar{R} < 0.7$, la estadística

$$Z = \frac{f(\bar{R}_1) - f(\bar{R}_2)}{0.893 \sqrt{\frac{1}{n_1-3} + \frac{1}{n_2-3}}}$$

(donde $f(\bar{R}) = \ln [x + \sqrt{1+x^2}]$, donde $x = \frac{\bar{R} - 1.0894}{0.2578}$) es computado y comparado

con la desviación normal convencional. En lugar de buscar valores críticos en las tablas, se calcula el nivel de confianza a partir de la estadística Z utilizando

$$D(Z) = \frac{1 + \operatorname{erf} \frac{Z}{\sqrt{2}}}{2} \cdot \text{Dado que}$$

la región crítica consiste en extremos iguales, el nivel de confianza se obtiene escribiendo $V_\alpha = 1 - 2 \times |D(Z) - 0.5|$. Para $\bar{R} < 0.7$, la estadística

$Z = \frac{n_1(1-R_1)(n_2-1)}{n_2(1-R_2)(n_1-1)}$ es computada y comparada con los valores críticos de

30

Fisher para la distribución con los grados de libertad n_1-1 y n_2-1 . Los valores críticos de Fisher pueden ser vistos en las tablas o hallados utilizando su función de distribución acumulativa de la siguiente manera:

31

$$F_{n,m}(x) = \frac{2n^{(n-2)/2} \left(\frac{x}{m}\right)^{n/2} {}_2F_1\left(\frac{m+n}{2}, \frac{n}{2}; 1, \frac{n}{2}; \frac{nx}{m}\right)}{\frac{\Gamma\left(\frac{n}{2}\right) \Gamma\left(\frac{m}{2}\right)}{\Gamma\left(\frac{n+m}{2}\right)}}$$

$${}_2F_1(a, b; c, z) = \frac{\Gamma(c)}{\Gamma(b) \Gamma(c-b)} \times \int_0^1 t^{b-1} (1-t)^{c-b-1} (1-tz)^{-a} dt$$

$${}_2F_1(a, b; c, z) = \frac{\Gamma(c)}{\Gamma(b) \Gamma(c-b)} \times \frac{1}{N} \sum_{t=0}^N \frac{\left(\frac{t}{N}\right)^{b-1} \left(1 - \frac{t}{N}\right)^{c-b-1}}{\left(1 - \frac{t}{N} z\right)^a}$$

Dado que la región crítica consiste en extremos iguales, el nivel de confianza se obtiene escribiendo $\forall_z = 1 - 2 \times |D(Z) - 0.5|$.

[0061] La segunda parte de la prueba paramétrica para determinar la repetibilidad de la distribución del campo de orientación es una prueba de direcciones medias iguales con un nivel de confianza $\forall_\mu$. En esta prueba, la estadística de la prueba

$$F_{1,N-2} = \frac{\left(1 + \frac{3}{8K}\right) (N-2) (n_1 \bar{R}_1 + n_2 \bar{R}_2 - N \bar{R})}{(N - n_1 \bar{R}_1 - n_2 \bar{R}_2)}$$

se computa y compara con los valores críticos de Fisher para la distribución con los grados de libertad 1 y $N-2$. Para esta prueba en particular los valores críticos de Fisher son proporcionados por una operación de búsqueda en tablas para el siguiente nivel de confianza $\forall_0 \{10\%, 5\%, 2.5\%, 1\%\}$. Si los datos no

31

están distribuidos normalmente (c.f. prueba de ji cuadrado para normalidad), o si el nivel de confianza para la prueba de igual concentración es $\forall \alpha < 0.005$, entonces el nivel de confianza para la prueba de repetibilidad recibe un valor de 0. De otra manera, el nivel de confianza de la prueba de direcciones medias es entonces el nivel de confianza $\forall \mu$ de la prueba de repetibilidad.

32

[0062] La parte de las concentraciones iguales o la parte de las direcciones medias iguales de la segunda prueba de repetibilidad puede fallar por las distribuciones muy estrechas de los ángulos y los altos valores de las concentraciones estimadas. Es probable que esto ocurra debido a que el valor de los estimados de las concentraciones se toman menos fiables cuando las distribuciones son estrechas o la prueba se hace más sensible si $\bar{R}_1$ y $\bar{R}_2$ están muy cercanos a 1 (tanto para la concentración como para la prueba de orientación media). En consecuencia, si se desea, se puede obviar la segunda prueba de repetibilidad cuando ambos estimados de κ sobrepasan el umbral de 20 y la diferencia de las direcciones medias es inferior a 15° . En forma más específica,

Si $([\kappa_1 > 20] \text{ y } [\kappa_2 > 20] \text{ y } [|\mu_1 - \mu_2| < 15^\circ])$

$$\forall = 1$$

además

ejecutar la segunda prueba de repetibilidad

terminar si

Una vez que la segunda prueba de repetibilidad se ha ejecutado para todos los

pares de zonas $C_p^2 = 36$ posibles, el puntaje de la segunda prueba de

repetibilidad se computa de la siguiente manera:

$$repetibilidad_2 = \frac{\sum_{i=1}^3 \sum_{j=1}^3 V_{z_i z_j}}{C_p^2}$$

Los detalles concernientes a la primera y la segunda partes de la segunda prueba de repetibilidad aparecen descritos en Mardia, "Statistics of Directional Data", Academic Press, New York, 1972, pp. 161-162 (concentración igual) y

32

pp. 152-155 (direcciones medias iguales), el cual es incorporado en su totalidad aquí por referencia.

33

[0063] Los puntajes de la primera y la segunda pruebas de repetibilidad se suman para obtener un puntaje total de repetibilidad (es decir, *repetibilidad* = *repetibilidad*₁ + *repetibilidad*₂).

Finalmente, se agrupan las pruebas de normalidad, no uniformidad y repetibilidad a una determinada escala (un tamaño dado del núcleo de orientación). Por ejemplo, se les agrupa de la siguiente manera:

$$\text{estacionaridad de orientación} = \frac{1}{4} \text{ normalidad} + \frac{1}{4} \text{ no uniformidad} + \frac{1}{2} \text{ repetibilidad}.$$

Preferiblemente el tamaño del núcleo se establece en ½ de la dimensión más pequeña de la imagen. Obsérvese que los puntajes de la estacionaridad de orientación se expresan en porcentajes.

[0064] La FIG. 7 ilustra las operaciones del bloque 111B (FIG. 1(B)) que caracterizan la estacionaridad de escala y afinidad de la imagen de entrenamiento del bloque 109. La estacionaridad de escala y afinidad de la imagen de entrenamiento depende de la rotación. En consecuencia, las operaciones en la imagen de entrenamiento (bloque etiquetado 701) comienzan computando el campo de orientación de la imagen de entrenamiento (bloque 703). De preferencia, el campo de orientación de la imagen de entrenamiento se computa usando la misma técnica y los mismos parámetros antes descritos con respecto a los bloques 407 a 409 de la FIG. 4. El campo de orientación se computa para todas las categorías de la imagen de entrenamiento. Los atributos texturales utilizados para computar las estadísticas de escala y afinidad son características extraídas de las Matrices de Co-ocurrencia de Niveles de Gris (explicadas más adelante con respecto a los bloques 709 y 719). Esta metodología requiere medir la diferencia de intensidad de niveles de gris entre pares adyacentes de píxeles en determinados desplazamientos. Cada píxel de la imagen se compara con píxeles de la misma imagen pero es llevado a un número de desplazamientos diferentes (en la realización preferida, 28 desplazamientos diferentes). Para un

33

desplazamiento en particular, los píxeles desplazados son agrupados en una imagen de desplazamiento. Por ello, en la realización preferida, tenemos 28 imágenes de desplazamiento. En los bloques 705 y 707, la imagen de entrenamiento es muestreada utilizando el campo de orientación como una guía para extraer un número de imágenes de desplazamiento diferentes (en la realización ilustrativa, 28 imágenes de desplazamiento diferentes). En la realización preferida que se describe más adelante, la información de orientación se integra a las imágenes de desplazamiento empleando muestreo dependiente de la rotación. Estas imágenes de desplazamiento se utilizan para computar las Matrices de Co-ocurrencia de Niveles de Gris de pequeñas ventanas deslizantes escaneadas sobre la imagen (bloque 709). Los vectores de características texturales son derivados de estas Matrices de Co-ocurrencia de Niveles de Gris (bloque 711).

[0065] En un trayecto paralelo, se selecciona una región (o zona) de la imagen de entrenamiento (bloque 713). Esta región o zona, la cual es identificada más adelante como patrón de referencia, tiene las mismas dimensiones que las ventanas deslizantes utilizadas en el bloque 709. Al igual que en las operaciones de los bloques 705 – 711, el patrón de referencia es muestreado utilizando el campo de orientación como guía (bloque 715). Sin embargo, cuando se muestrea la imagen pequeña del patrón de referencia, no solamente se corrige la imagen para la orientación sino que se imponen diferentes transformaciones de afinidad al sistema de adyacencia circular empleado para el muestreo. Al modificar los factores de afinidad, se obtienen diferentes escalas y alargamientos a lo largo de los ejes X e Y, por lo que se derivan imágenes de desplazamiento en diferentes afinidades (bloque 717). De este modo, en la realización preferida, en lugar de tener sólo 28 imágenes de desplazamiento y 1 vector de atributos texturales (como es el caso para la imagen de entrenamiento), Las operaciones generan, a partir del patrón de referencia, $28 \times N$ imágenes de desplazamiento y N vectores de atributos texturales para el patrón de referencia, donde N es un número de parejas de afinidad (X, Y). Por cada selección de la afinidad X e Y, se realiza un muestreo dependiente de la rotación del patrón de referencia. En la realización ilustrativa que se muestra en la FIG. 10, se escoge N para que sea igual a 25 con 5

valores posibles para la afinidad a lo largo del eje X (es decir, $x0.5$, $x0.667$, $x1$, $x1.5$, $x2$) y 5 valores posibles para la afinidad a lo largo del eje Y (es decir, $x0.5$, $x0.667$, $x1$, $x1.5$, $x2$). Las imágenes de desplazamiento generadas en el bloque 719 se emplean para computar las Matrices de Co-ocurrencia de Niveles de Gris de las pequeñas ventanas deslizantes escaneadas sobre la imagen (bloque 719). Los vectores de características texturales son derivados de estas Matrices de Co-ocurrencia de Niveles de Gris (bloque 721). Los vectores de características texturales generados en el bloque 721 se derivan de distintas transformaciones de escala (que en ocasiones son identificadas aquí como "dilataciones de afinidad") del mismo patrón de referencia. En el bloque 723, las operaciones miden la similitud (es decir, la distancia euclidiana) entre los vectores de características texturales generados en el bloque 721 y los vectores de características texturales generados en el bloque 711. En el bloque 725, para una zona determinada (ventana deslizante) de la imagen de entrenamiento, las operaciones seleccionan la transformación de afinidad que produce una versión dilatada del patrón de referencia que minimiza la medida de similitud calculada en el bloque 723. Estos resultados pueden interpretarse como un mapa de afinidad de la imagen de entrenamiento bajo la presunción de que se reproduce un solo patrón de referencia sobre toda la imagen en diferentes escalas. En el bloque 727, las estadísticas de estacionaridad y el puntaje se computan empleando las transformaciones de afinidad identificadas en el bloque 725. En el bloque 729 también pueden aparecer los mapas de afinidad (también denominados aquí como mapas de similitud). Las estadísticas y el puntaje computados en el bloque 727 y el mapa de afinidad presentado en el bloque 729 se relacionan con el patrón de referencia seleccionado en el bloque 713.

[0066] En el bloque 731 se determina si las operaciones deberían ser revertidas hasta el bloque 713. La decisión puede tomarse de acuerdo con la información que ingrese el usuario o de manera automática mediante una ventana deslizante. Si la decisión en el bloque 731 es si, se selecciona otro patrón de referencia en el bloque 713 y las estadísticas de estacionaridad y un puntaje relacionado con éstas son generadas en los bloques 715-729 según lo antes descrito. Si la decisión en el bloque 731 es no, en el bloque 733 se puede

computar un promedio de los puntajes generados en el bloque 727 sobre un número de patrones de referencia y/o en el bloque 735 se puede mostrar un mapa de afinidad compuesto derivado de los mapas de afinidad generados en el bloque 725 sobre un número de patrones de referencia, y termina el procesamiento.

[0067] En la realización preferida, la derivación de las imágenes de desplazamiento en los bloques 705/707 y en los bloques 715/717 emplean el principal del sistema de adyacencia circular de N^{ma} orden, el cual es descrito en detalle en Deng y otros, "Gaussian MRF Rotation-Invariant Features for Image Classification", IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 26, No. 7, Julio 2004. En forma más particular, este sistema de adyacencia circular isotrópico se utiliza para el muestreo de píxeles adyacentes relacionados con el píxel central de referencia. Todos los adyacentes muestreados son colocados en círculos concéntricos de radio de píxel $r=1, r=2, r=3, \dots, r=N$ donde N es el orden del adyacencia. Se puede emplear una interpolación bilineal para interpolar los valores de intensidad de las muestras que no caigan exactamente en el centro de los píxeles. La FIG. 8 ilustra el sistema de adyacencia circular de 4^{to} orden que se utiliza en la realización preferida, con las muestras 4, 6, 8 y 100 respectivamente tomadas en semicírculos de radio $r=1, r=2, r=3, \dots, r=4$. Estas muestras se suman para obtener $4 + 6 + 8 + 10 = 28$ puntos de desplazamiento de la siguiente manera:

$$\begin{aligned} \square k \in [1,4], & \begin{cases} \theta_k = \frac{(k-1)\pi}{4} \\ u_k = r_1 \cos(\theta_k) \\ v_k = r_1 \sin(\theta_k) \end{cases} & \square k \in [5,10], & \begin{cases} \theta_k = \frac{(k-5)\pi}{6} \\ u_k = r_2 \cos(\theta_k) \\ v_k = r_2 \sin(\theta_k) \end{cases} \\ \square k \in [11,8], & \begin{cases} \theta_k = \frac{(k-11)\pi}{8} \\ u_k = r_3 \cos(\theta_k) \\ v_k = r_3 \sin(\theta_k) \end{cases} & \square k \in [19,10], & \begin{cases} \theta_k = \frac{(k-19)\pi}{10} \\ u_k = r_4 \cos(\theta_k) \\ v_k = r_4 \sin(\theta_k) \end{cases} \end{aligned}$$

Este muestreo ofrece la ventaja de proporcionar una cobertura completa de cada píxel en el adyacencia circular sin caer en la trampa de muestrear varias veces el mismo píxel o par de píxeles.

37

[0068] Para las operaciones de los bloques 705 y 707 que generan las imágenes de desplazamiento para la imagen de entrenamiento, el sistema de adyacencia circular es adaptado para el muestreo dependiente de la rotación. Más específicamente, sean u y v los vectores de la columna de coordenadas de los puntos de muestreo en el plano X-Y para un ángulo de rotación de 0, y sean u' y v' su resultado luego de una rotación de un ángulo ϕ en el muestreo de adyacencia dependiente de la rotación. La rotación por un ángulo ϕ de las coordenadas del muestreo de adyacencia es entonces:

$$\begin{pmatrix} u'^T \\ v'^T \end{pmatrix} = \begin{pmatrix} \cos(\phi) & \sin(\phi) \\ -\sin(\phi) & \cos(\phi) \end{pmatrix} \begin{pmatrix} u^T \\ v^T \end{pmatrix}$$

La FIG. 9 muestra una realización ilustrativa de este muestreo dependiente de la rotación empleando un sistema de muestreo de adyacencia circular de 4^{to} orden, con una rotación ϕ de 60 grados. La realización de la FIG. 9 también contempla el muestreo dependiente de escala, el cual se describe más adelante pero que puede ser ignorado para los efectos de los bloques 705 y 707. Al igual que el muestreo de adyacencia no rotado, se puede emplear una interpolación bilineal para interpolar los valores de intensidad de las muestras que no caigan exactamente en el centro de los píxeles. En vista de que la representación de la imagen en la pantalla emplea el sistema de coordenadas cartesianas indirectas donde el eje Y está invertido y orientado hacia abajo en tanto que el eje X sigue orientado hacia la derecha, se aplica una rotación mediante un ángulo de $-\phi$ a las coordenadas del muestreo de adyacencia circular. Los parámetros de rotación del sistema de muestreo de adyacencia antes descrito se derivan de los vectores del campo de orientación computados en el bloque 703. Específicamente, por cada píxel de la imagen de entrenamiento o cada píxel del patrón de referencia, existe un valor de la dirección ϕ del vector de orientación, produciendo el parámetro ϕ de la rotación del sistema de muestreo de adyacencia. En la realización preferida, el

37

muestreo de adyacencia circular rotado produce 28 píxeles desplazados por cada píxel de la imagen de entrenamiento. De esta manera, el muestreo dependiente de la rotación produce 28 imágenes de desplazamiento de la imagen de entrenamiento para su posterior análisis en el bloque 711.

[0069] Para las operaciones de los bloques 715 y 717 que generan las imágenes de desplazamiento para un determinado patrón de referencia, el sistema de adyacencia circular es adaptado para el muestreo dependiente de la rotación y de la escala. Más específicamente, se emplea una transformación de afinidad del sistema de muestreo de adyacencia circular de n^{ma} orden a fin de capturar las características texturales en una determinada escala X e Y local y en una orientación local dada. Este enfoque es lo contrario de la generación estocástica de imágenes a través de la geoestadística de puntos múltiples. De hecho, como lo explica Caers, "Geostatistical history matching under training-image based geological model constraints", SPE Journal, No. 74716, 2003, pp. 218-226, la escala local (afinidad) y la información de orientación se pueden utilizar para controlar la realización de un proceso estocástico y permitir la repetición de un patrón en escalas y orientaciones variantes. Los factores de afinidad a_x y a_y describen la transformación (dilatación) de escala del patrón de referencia a lo largo del eje X y del eje Y, respectivamente. En la realización ilustrativa que se muestra en la FIG. 10, hay 5 valores posibles para el factor de afinidad a_x (es decir, x0.5, x0.667, x1, x1.5, x2) y 5 valores posibles para el factor de afinidad a_y (es decir, x0.5, x0.667, x1, x1.5, x2), con lo que se tiene un total de 25 pares (o parejas) de factores de afinidad diferentes. Cuando la relación de aspecto a_y/a_x no es 1, entonces se alarga ese patrón a lo largo del eje X y del eje Y. La afinidad total y la transformación de rotación de las coordenadas del muestreo de adyacencia circular pueden escribirse de la siguiente manera:

$$\begin{bmatrix} u''^T \\ v''^T \end{bmatrix} = \begin{bmatrix} \cos(\phi) & \sin(\phi) \\ -\sin(\phi) & \cos(\phi) \end{bmatrix} \begin{bmatrix} a_x & 0 \\ 0 & a_y \end{bmatrix} \begin{bmatrix} u^T \\ v^T \end{bmatrix}$$

En la FIG. 9 se aprecia un ejemplo de un sistema de muestreo de adyacencia circular de 4^{to} orden rotado y escalado con una rotación ϕ de 60 grados y la

pareja de factores de afinidad $(a_x, a_y) = (0.5, 1)$. El factor de afinidad a_x de 0.5 indica que el muestreo de adyacencia se agranda a lo largo del eje X cuando se muestrea el patrón. Esto equivale a dilatar el patrón de referencia por un factor de 2 a lo largo del eje X. Los parámetros de rotación del sistema de muestreo de adyacencia antes descrito se derivan de los vectores del campo de orientación computados en el bloque 703. Más específicamente, por cada píxel de la imagen de entrenamiento o cada píxel del patrón de referencia, existe un valor de la dirección ϕ del vector de orientación, produciendo el parámetro ϕ de la rotación del sistema de muestreo de adyacencia. Los parámetros de afinidad (a_x, a_y) son constantes en toda la imagen. Sin embargo, por cada juego de esos parámetros de afinidad se computa un nuevo juego de imágenes de desplazamiento para su posterior análisis en el bloque 721. En la realización preferida, el muestreo de adyacencia circular dependiente de la rotación y de la escala produce 25 juegos de 28 píxeles desplazados por cada píxel del patrón de referencia, un juego por cada combinación de factores de afinidad X e Y. De esta manera, el muestreo dependiente de la rotación y de la escala produce 25 juegos de 28 imágenes de desplazamiento del patrón de referencia para su posterior análisis en el bloque 721.

[0070] Tal como se ha descrito anteriormente, las operaciones de los bloques 709 y 711 derivan características texturales (identificados más adelante como "atributos texturales" o "elementos") de matrices de co-ocurrencia de niveles de gris computadas en las imágenes de desplazamiento de la imagen de entrenamiento. En la realización preferida, las matrices de co-ocurrencia de niveles de gris se computan de la siguiente manera. Primero, la imagen de entrenamiento y las imágenes de desplazamiento son cuantificadas en niveles de gris G (por ejemplo, $G = 32$). Nótese que aun cuando se realiza un análisis de múltiples resoluciones de patrones en blanco y negro, se utilizan más de 2 niveles de gris ya que durante el muestreo de adyacencia circular con transformaciones de escala y orientación, la mayoría de las muestras no caen en los centros de los píxeles y quedan interpoladas. Además, si hay más de 2 pero menos de categoría G en la imagen de entrenamiento, la cuantificación de los niveles de gris permite que las operaciones mantengan una diferenciación

entre cada categoría. Luego las imágenes cuantificadas son procesadas para computar un juego de matrices de co-ocurrencia. Cada matriz de co-ocurrencia, la cual puede ser llamada $C_d(k,l)$, estima la probabilidad de niveles de gris k y l que pueden ocurrir en la imagen cuantificada $I(x, y)$ en un desplazamiento de d . La probabilidad se mide contando el número de pares (x, y) y (x', y') donde $I(x, y) = k$, $I(x', y') = l$ y $(x'-x, y'-y) = d$, y luego dividiendo ese número de pares entre el número total de píxeles adyacentes en la imagen. El juego de matrices de co-ocurrencia se genera comparando cada una de las imágenes de desplazamiento cuantificadas con la imagen de entrenamiento cuantificada. En la realización preferida se obtienen 28 matrices de co-ocurrencia $C_d(k,l)$. Para un desplazamiento dado d , o para una pareja dada (imagen de entrenamiento, imagen de desplazamiento), cada elemento de la matriz de co-ocurrencia sigue la siguiente fórmula:

$$C_d(k, l) = \Pr [I(x', y') = l | I(x, y) = k].$$

Como se muestra en la FIG. 11, cada matriz de co-ocurrencia no se computa en toda la imagen de entrenamiento sino en una pequeña ventana deslizante extraída de la imagen y muestreada con regularidad. La FIG. 11 ilustra la generación de matrices de co-ocurrencia (y los vectores de características texturales derivados de las mismas). En la FIG. 11, las tres regiones a, b y c ilustran las posibles ubicaciones de la ventana deslizante. En la realización preferida, las ubicaciones de la ventana deslizante son muestreadas con regularidad sobre toda la imagen de entrenamiento. Por cada una de las regiones a, b y c de la FIG. 11, hay 28 imágenes de desplazamiento que son interpoladas y 28 matrices de co-ocurrencia subsiguientes y estadísticas de matrices de co-ocurrencia que son computadas. Nótese que si se aumenta el tamaño de la ventana deslizante, se capturan más características texturales pero se reduce la resolución de los mapas de afinidad que se derivan de éstos en el bloque 725.

[0071] Luego de haber computado el juego de matrices de co-ocurrencia, se computan seis características texturales a partir de cada matriz de co-ocurrencia utilizando las siguientes fórmulas, (donde $p(k, l)$ es un elemento de una matriz de co-ocurrencia dada):

$$\text{i) Energía (segundo momento angular): } \sum_{k=0}^{G-1} \sum_{l=0}^{G-1} [p(k, l)]^2;$$

$$\text{ii) Contraste (inercia): } \sum_{k=0}^{G-1} \sum_{l=0}^{G-1} (k - l)^2 p(k, l);$$

$$\text{iii) Disimilitud (valor absoluto): } \sum_{k=0}^{G-1} \sum_{l=0}^{G-1} |k - l| p(k, l);$$

$$\text{iv) Diferencia inversa: } \sum_{k=0}^{G-1} \sum_{l=0}^{G-1} \frac{p(k, l)}{1 + (k - l)^2};$$

$$\text{v) Entropía: } - \sum_{k=0}^{G-1} \sum_{l=0}^{G-1} p(k, l) \log_2 [p(k, l)]; \text{ y}$$

$$\text{vi) Máxima probabilidad: } \max_{k, l} p(k, l).$$

Detalles más específicos acerca de estos descriptores pueden encontrarse en Haralick y otros, "Textura Features for Image Classification", IEEE Transactions on Systems Man and Cybernetics, SMC-3, No. 6, 1973, pp. 610-621, y Materka y otros, "Textura Analysis Methods – A Review", Technical University of Lodz, Institute of Electronics, COST B11 report, Bruselas, 1998, incorporados en su totalidad aquí por referencia. De esta manera, un vector de 6 elementos caracteriza cada matriz de co-ocurrencia, lo cual reduce la dimensionalidad de las medidas texturales. En la realización preferida, las 6 características texturales para cada una de las 28 matrices de co-ocurrencia son agrupadas para generar un vector de 168 elementos que están asociados a la imagen de entrenamiento.

[0072] En la realización preferida, operaciones similares a las descritas anteriormente con respecto a los bloques 709 y 711 se realizan para derivar

características texturales de matrices de co-ocurrencia de niveles de gris computadas en las imágenes de desplazamiento del patrón de referencia en los bloques 719 y 721. En esas operaciones, se computa un juego de matrices de co-ocurrencia (preferiblemente 28) por cada pareja de factores de afinidad computada (es decir, por cada una de las 25 parejas de factores de afinidad). Cada matriz de co-ocurrencia se computa sobre todo el patrón de referencia. Entonces se generan las 6 características texturales para cada matriz de co-ocurrencia. En la realización preferida se generan 25 vectores de características texturales (cada vector conteniendo 168 elementos). Los 25 vectores se corresponden con las 25 parejas de factores de afinidad antes descritas con respecto a la FIG. 10.

[0073] Tal como se ha descrito anteriormente, las operaciones del bloque 723 miden la similitud (es decir, una distancia euclidiana) entre los vectores de características texturales generados en el bloque 721 y los vectores de características texturales generados en el bloque 711. En la realización preferida, esto se logra generando, para cada región r de la imagen de entrenamiento, la dilatación a (de 25 posibles dilataciones aff) del patrón de referencia que minimiza la distancia euclidiana entre los vectores de características texturales $V_{T,r}$ y $V_{RP,aff}$, lo cual se representa matemáticamente de la siguiente manera:

$$a(r) = \arg \min_{aff} \left(3 \sum_{i=1}^N [V_{T,r}(i) - V_{RP,aff}(i)]^2 \right)$$

La dilatación $a(r)$ se computa por cada región r conforme lo indican las flechas delgadas que enlazan los pares de vectores de características en la FIG. 11. La FIG. 11 ilustra la comparación entre los vectores de características texturales para tres regiones distintas a , b , c de la imagen de entrenamiento y las diferentes transformaciones de afinidad del patrón de referencia, denotadas (x_1, y_1) , (x_2, y_2) , $(x_3, y_3) \dots (x_N, y_N)$.

[0074] La mínima distancia euclidiana entre los vectores de características produce un mapa de afinidad que muestra los mejores factores de afinidad para las regiones de la imagen de entrenamiento. FIG. 11 muestra

un ejemplo de mapa de afinidad en el que se dan los mejores parámetros de afinidad (x_a, y_a) , (x_b, y_b) , (x_c, y_c) para las regiones a, b y c respectivamente. Este mapa de afinidad puede mostrarse en el bloque 729 conforme ya se ha descrito.

43

[0075] Las FIGS. 12(B) y 12(C) ilustran otra forma del mapa de afinidad en el que se proporcionan las imágenes bidimensionales separadas para las parejas de factores de afinidad. Cada imagen bidimensional describe la distancia entre los vectores de características para las correspondientes partes en la imagen de entrenamiento y el patrón de referencia. En el mapa de afinidad de la FIG. 12(B), los píxeles de cada imagen bidimensional están en escala de grises con las distancias representadas por los píxeles cuantificados en un rango de valores de escala de grises. En el mapa de afinidad de la FIG. 12(C), los píxeles de cada imagen bidimensional son binarios y la distancia está representada por los píxeles asignados a una escala binaria de valores. Las distancias más cercanas son asignadas a un valor binario (es decir, negro) mientras que las demás distancias son asignadas a otro valor binario (es decir, blanco). En el ejemplo de las FIGS. 12(A) - 12(C), la imagen de la FIG. 12(A) se obtiene copiando/pegando una imagen de entrenamiento clásica (en la esquina superior izquierda) a diversas transformaciones de afinidad en el resto de la imagen: en la esquina superior izquierda, el patrón tiene una transformación de afinidad $(a_x=1, a_y=1)$; la esquina superior derecha, se reproduce el patrón dos veces en una transformación de afinidad $(a_x=1, a_y=0.5)$; en la parte media izquierda de la imagen se reproduce el patrón dos veces en una transformación de afinidad $(a_x=0.5, a_y=1)$; en la parte media derecha de la imagen se reproduce el patrón 4 veces en una transformación de afinidad $(a_x=0.5, a_y=0.5)$; en la parte inferior de la imagen el patrón tiene una transformación de afinidad $(a_x=2, a_y=1)$. Toda la imagen de la FIG. 12(A) es la imagen de entrenamiento. El rectángulo resaltado en la esquina superior izquierda de la imagen de la FIG. 12(A) es seleccionado como el patrón de referencia. El mapa de afinidad de la FIG. 12(B) muestra la distancia en escala de grises entre los vectores de características texturales extraídos de la imagen de entrenamiento y los vectores de características texturales del patrón de referencia para 9 parejas de factores de afinidad diferentes. El mapa de afinidad de la FIG. 12(C) muestra la

43

44

distancia binaria (es decir, las distancias más cercanas en negro) entre los vectores de características texturales extraídos de la imagen de entrenamiento y los vectores de características texturales del patrón de referencia para 9 parejas de factores de afinidad diferentes. La correlación entre la afinidad visible de la imagen de entrenamiento y los resultados es muy buena ya que la metodología detecta una afinidad ($a_x=2$, $a_y=1$) para la mayoría de los píxeles en la parte inferior de la imagen de entrenamiento, una afinidad ($a_x=0.5$, $a_y=1$) para la mayoría de los píxeles en la parte media izquierda de la imagen de entrenamiento, una afinidad ($a_x=0.5$, $a_y=0.5$) para la mayoría de los píxeles en la parte media derecha de la imagen de entrenamiento, y una afinidad ($a_x=1$, $a_y=0.5$) para la mayoría de los píxeles en la esquina superior derecha de la imagen de entrenamiento. El algoritmo también detecta una afinidad ($a_x=1$, $a_y=1$) en dos ubicaciones de la imagen de entrenamiento: tal como se espera, en la esquina superior izquierda de la imagen de entrenamiento que también fue utilizada como patrón de referencia y hacia la parte inferior de la imagen de entrenamiento. Este artefacto en la afinidad ($a_x=1$, $a_y=1$) se debe a la discontinuidad de marginal en la imagen bidimensional, la cual se interpreta como un cambio de escala.

[0076] En la realización preferida, las operaciones del bloque 727 utilizan los principios de los mapas de afinidad antes descritos para generar estadísticas de estacionaridad de escala. La estacionaridad de escala, con respecto a un patrón de referencia, se puede medir determinando cuántas escalas diferentes (y relaciones de aspectos) son cubiertas por esa imagen, o cómo la imagen se extiende en un espacio de escala cuando se presume que la imagen se deriva de la repetición de un patrón único en diferentes escalas y orientaciones. Más específicamente, la estacionaridad de escala puede definirse como la partida desde un solo valor conglomerado de (X_{x1} , Y_{x1}) en el mapa de afinidad; por ello toda variación en el eje X o en el eje Y del mapa de afinidad indica una imagen no estacionaria. En la realización preferida, la estacionaridad de escala de la imagen se mide calculando la dispersión de la nube de puntos p_1 , p_2 , ... p_n definidos por las mejores concordancias entre la imagen y los patrones dilatados. La medida de la dispersión se puede computar sencillamente como una medida de dispersión de puntos en un espacio

bidimensional, como se muestra en la FIG. 13. Estos puntos de mejor concordancia están ubicados en un escala-espacio donde el eje X corresponde a la posible dilatación a lo largo del eje X y el eje Y a las posibles dilataciones a lo largo del eje Y. Cada uno de estos puntos, que pueden representar una pequeña zona diferente en la imagen, describe por su ubicación en la escala-espacio, los factores de dilatación x e y . La escala-espacio no es continua pero si discreta dado que solamente se computa un pequeño número de dilataciones del patrón de referencia. Los factores de dilatación son mapeados en la escala-espacio mediante una bisección (es decir, un mapeo de uno en uno). En la realización preferida, los factores de dilatación x son $1/2, 2/3, 1, 3/2$ y 2 y se corresponden con las abscisas de $-1, -1/2, 0, 1/2$ y 1 . Esta escala-espacio aparece representada en la FIG. 13. En este ejemplo, la representación escala-espacio de la dispersión de una nube de puntos se simboliza con una elipse. Se muestran la primera y la segunda direcciones de componentes principales. Los dos componentes principales de los puntos $p_1, p_2, \dots, p_n$ se obtienen mediante la descomposición del valor singular

$$(DVS) \begin{pmatrix} x_i \\ y_i \end{pmatrix}_{i \in \{1, n\}} = UxSxV^T. \text{ El primer componente principal da la dirección de la}$$

variación más fuerte de los puntos y el segundo componente principal es ortogonal al primero y da las direcciones de la variación más débil de los puntos. La relación s_2/s_1 de los dos valores singulares s_1 y s_2 (los cuales pueden ser recuperados de la diagonal de la matriz S) da la importancia de variación de los puntos $p_1, p_2, \dots, p_n$ a lo largo de la dirección de la segunda dirección principal. Sea $u = (u_x, u_y)$ el vector unitario que define la dirección del primer componente principal y sea $v = (v_x, v_y)$ el vector unitario que define la dirección del segundo componente principal (u y v son ortogonales). Los vectores unitarios u y v pueden obtenerse normalizando la primera y la segunda columnas de la matriz V . Las coordenadas de $p_1, p_2, \dots, p_n$ en el sistema de

$$\text{coordenadas } u, v \text{ se pueden obtener de } \begin{pmatrix} u_i \\ v_i \end{pmatrix}_{i \in \{1, n\}} = Ux \begin{pmatrix} x_i \\ y_i \end{pmatrix}_{i \in \{1, n\}}. \text{ La dispersión}$$

de la nube de puntos se define como dependiente tanto de la varianza a lo largo de la primera dirección principal y el efecto de la varianza a lo largo de la

segunda dirección principal ortogonal. La variabilidad a lo largo de la primera dirección principal se computa de la siguiente manera:

46

$$\text{stdev}(u_i)_{i=1,n} = \sqrt{\frac{1}{n-1} \sum_{j=1}^n (u_j - \bar{u})^2} \text{ donde } \bar{u} = \frac{1}{n} \sum_{j=1}^n u_j. \text{ La dispersión total de la}$$

nube de los puntos $p_1, p_2, \dots, p_n$ se define de la siguiente manera:

$$\text{dispersión} = \min \left\{ 1, \text{stdev}(u_i)_{i=1,n} \times \left[1 + \frac{s_2}{s_1} \right] \right\}.$$

Esta fórmula ha sido concebida para proporcionar una dispersión más poderosa cuando la nube de puntos tiene una forma elíptica o circular que cuando la nube está solamente con una constante de la relación X/Y. Además, también se encuentra limitada entre los valores de 0 (todos los puntos están concentrados en el punto medio (0, 0), es decir, todas las escalas son x1, x1) y 1. El puntaje de la escala de estacionaridad es simplemente 1-dispersión (es decir, *estacionaridad de escala* = 1 - *dispersión*) y se expresa como porcentaje. En la realización preferida se emplea una computación de puntaje de estacionaridad de escala totalmente automatizada en el bloque 727 que calcula el valor mínimo de 9 puntajes de estacionaridad de escala computados con patrones de referencia localizados en la parte superior derecha, la parte superior media, la parte superior izquierda, la parte media derecha, el centro, la parte media izquierda, la parte inferior derecha, la parte inferior media y la parte inferior izquierda de la imagen de entrenamiento, lo cual es similar a la computación del puntaje de estacionaridad de orientación antes descrita. Estas operaciones pueden ser representadas matemáticamente como

$$\text{estacionaridad de escala} = \min_{k=1}^9 (\text{estacionaridad de escala}_k).$$

[0077] Las operaciones del bloque 111C (FIG. 1(B)) que caracterizan la estacionaridad de distribución de categorías de la imagen de entrenamiento del bloque 109 verifican que la distribución de categorías no cambia considerablemente de una región de la imagen a otra. En la realización preferida, la imagen de entrenamiento se subdivide en zonas de una manera similar a la antes descrita con respecto a las FIGS. 6(A) – 6(I) al generar las estadísticas de estacionaridad de orientación. Un histograma de distribución de

46

categorías H_k se computa en cada zona k de las 9 zonas de la realización preferida. Todos los histogramas de distribución de categorías contienen bins G , donde G es el número de categorías. La similitud de dos histogramas en escala de grises H_k y H_l se mide utilizando la distancia euclidiana entre los vectores H_k y H_l :

$$\sqrt{\frac{1}{G} \sum_{c=1}^G [H_k(c) - H_l(c)]^2}$$

[0078] El puntaje de la estacionaridad de distribución de categorías para todas las zonas se computa de la siguiente manera:

$$\text{estacionaridad de clase de color} = 1 - \min \left[1, \max_{k,l} \left(\sqrt{\frac{1}{G} \sum_{c=1}^G [H_k(c) - H_l(c)]^2} \right) \right]$$

[0079] En el bloque 113, los puntajes de estacionaridad generados en el bloque 111 se analizan para determinar si la imagen de entrenamiento satisface un conjunto de limitaciones predeterminadas que establecen si la imagen de entrenamiento debe ser utilizada o no en posteriores análisis geoestadísticos de puntos múltiples. En la realización preferida, el puntaje de la estacionaridad de orientación (111A), el puntaje de la estacionaridad de escala (111B) y el puntaje de la estacionaridad de distribución de categorías (111C) son plasmados en un gráfico dimensional cuyos ejes corresponden a los tres puntajes, tal como se muestra en la FIG. 14. Se define un conjunto de superficies que representan una o más regiones en el espacio tridimensional que delimita las imágenes de entrenamiento "buenas". Si los tres puntajes para la imagen de entrenamiento en particular caen dentro de una o más regiones que delimitan las imágenes de entrenamiento "buenas", se satisface el criterio de estacionaridad del bloque 113; de no ser así, no se cumple con el criterio de estacionaridad del bloque 113.

[0080] En caso de que el criterio de estacionaridad del bloque 113 sea satisfecho, la imagen de entrenamiento puede ser exportada como una cuadrícula de imagen para análisis geoestadísticos de puntos múltiples (bloque 119). Entre los ejemplos de tales análisis geoestadísticos de puntos múltiples

47

47

se encuentran la implementación computarizada del algoritmo SNESIM y/o la implementación computarizada del algoritmo SIMPAT.

48

[0081] En el método SNESIM (Single Normal Equation Simulator), la función condicional de densidad de probabilidades de todas las categorías en un punto se computa utilizando el valor conocido de un pequeño número de puntos cercanos y las estadísticas proporcionadas por una "imagen de entrenamiento". El SNESIM trabaja con valores discretos solamente (es decir, un número finito y generalmente pequeño de categorías, como por ejemplo, cinco tipos de rocas diferentes). Se asume que hay dos categorías que simular: A (intracanal) y B (canal). La imagen de entrenamiento contiene una representación completa (es decir, un ejemplo) de una distribución espacial de A y B. Se asume además que la categoría presente en 4 puntos (u_1, u_2, u_3, u_4) que podrían representar pozos es conocida. Conceptualmente, el método SNESIM calcula la probabilidad de encontrar las categorías A y B en un quinto punto (u_7) mediante la consulta de la imagen de entrenamiento para determinar todas las ocurrencias del "patrón" (u_1, u_2, u_3, u_4) (es decir, todas las ocurrencias de los 4 puntos con las mismas ubicaciones relativas entre sí y los mismos valores de categorías en la imagen de entrenamiento) como se muestra en la FIG. 15. Si se encuentran las 5 categorías (a las que se les llama réplicas) y 4 o 5 de las réplicas muestran categorías B en la posición relativa del punto desconocido (u_7), entonces el método concluye que la probabilidad de B en el punto desconocido es de 80% (en tanto que la de A es de 20%). Además, el método puede asignarle una categoría al punto desconocido extrayendo aleatoriamente un valor de una distribución con 80% de probabilidad de B y 20% de probabilidad de A. En la práctica el método SNESIM se inicia con un volumen en blanco que debe ser modelado o uno que contiene pocos puntos de datos que atender, y primero se decide un trayecto aleatorio para visitar cada píxel en blanco una sola vez y solo una. En el primer píxel el método exige buscar los puntos cercanos conocidos dentro de una elipsoide de búsqueda. Si se hallan uno o más píxeles conocidos (o ya asignados), se procede de la manera descrita anteriormente a fin de hallar la probabilidad A o B en el punto desconocido. Armado con las probabilidades para cada categoría en el punto desconocido, el método extrae en forma aleatoria un valor

48

(ponderado por las probabilidades conocidas y se lo asigna a un punto desconocido. El proceso se repite en el siguiente píxel en el trayecto aleatorio inicialmente asignado hasta que todos los píxeles quedan asignados.

49

[0082] Esta metodología era bien conocida en la década de los 90 (antes de fuera llamada "SNESIM"). Uno de sus problemas, sin embargo, era que sumamente intensiva a nivel de cómputos para poder consultar la imagen de entrenamiento numerosas veces. En el año 2000, se descubrió una técnica para almacenar la información contenida en la imagen de entrenamiento en una estructura especial con forma de árbol que permitía reducir considerablemente los cómputos. Con esta mejora, la metodología pasó a ser conocida comúnmente como método SNESIM. Al ser acoplada con el creciente poder de las computadoras digitales, permitió reducir el problema de la consulta de imágenes a unos tiempos de procesamiento razonables (pero aun significativos).

[0083] La metodología SNESIM tiene distintas variaciones y adiciones que pueden emplearse para hacerla más poderosa y útil. Una mejora incorpora la capacidad de procesar en etapas sucesivas de resolución creciente, lo cual mejora la continuidad lateral de las características. El número de refinamientos se denomina multiplicidad. Otra mejora brinda la capacidad de utilizar probabilidades suaves (posiblemente derivadas de datos sísmicos) para mayor control del modelado. Mediante otras adiciones, el método SNESIM puede manejar transformaciones de escala simplemente con escalar las distancias hasta los puntos conocidos ((u_1, u_2, u_3, u_4) en el ejemplo anterior) según la información de escalación dependiente de la ubicación proporcionada por el usuario. Igualmente puede incorporar información a la rotación de las características geológicas (tales como direcciones de canal) haciendo rotar el conjunto de puntos según el valor local de un campo de rotación suministrado por el usuario.

[0084] En el método SIMPAT (SIMulation with PATterns), se calcula la probabilidad de ocurrencia de todas las combinaciones de valores dentro de un pequeño conjunto de puntos contiguos (como una matriz rectangular). A

50

diferencia del método SNESIM, el método SIMPAT puede trabajar tanto con valores (de categoría) discretos como con valores numéricos continuos. Específicamente, el método SIMPAT calcula tales probabilidades en la imagen de entrenamiento mediante el conteo de las ocurrencias de estos patrones desplazando una plantilla rectangular que escanea toda la imagen. Por ejemplo, si se aplica a una imagen binaria bidimensional con una plantilla de 2x2 píxeles, el método asigna una probabilidad de ocurrencia a todo posible resultado de la plantilla de 2x2 píxeles (es decir, 24 o 16 posibles resultados). El resultado es una distribución de probabilidades cuyo dominio consiste en 24 combinaciones de píxeles, como se muestra en la FIG. 16(A). En la práctica, las plantillas más grandes (de hasta unos 8x8 píxeles) se utilizan para obtener un gran número de posibles combinaciones, aunque muchas pueden tener una ocurrencia o probabilidad de cero si se encuentran ausentes en la imagen de adiestramiento. La simulación se logra extrayendo en forma aleatoria de la distribución hasta llenar progresivamente una imagen inicialmente vacía. Es preciso tener cuidado al trabajar con píxeles ya llenos o con píxeles que representan datos de condicionamiento difícil. Esto puede lograrse mediante extracción de un subconjunto de la distribución original de los grupos de píxeles, a saber, los subconjuntos de aquellos grupos de píxeles que trabajan con los datos pre-existentes.

[0085] La necesidad de hacer concordar los puntos pre-existentes puede conducir a prolongados lapsos de cálculo con patrones de mayor tamaño porque muchos puntos necesitan ser concordados simultáneamente a lo largo de las fronteras de los patrones de mayor tamaño. Esto ha llevado a la utilización de un método algo más refinado denominado geoestadística "basada en características" y el cual se fundamenta en una plantilla que contiene una "característica" interna y una "piel" externa, tal como se aprecia en la FIG 16(B). En la práctica, la característica por lo general es mayor de 2x2 píxeles, pero la piel comúnmente tiene un píxel de ancho. Esta partición permite la clasificación de la plantilla. Al escanear la imagen, el método obtiene una serie de características y sus probabilidades de ocurrencia. Una característica dada (2x2 en este ejemplo) puede ocurrir varias veces, pero cada vez con una piel diferente. En consecuencia, cada característica tiene una probabilidad pero

51
muchas pieles posibles, cada una de las cuales a su vez posee su probabilidad (con relación a la característica). Cuando una característica necesita ser asignada junto a otra ya existente, se le extrae de todas las características con una piel concordante, ponderada por la probabilidad de cada posible piel en la característica existente. De este modo la piel limita la probabilidad de ocurrencia de las características en su adyacencia inmediata y permite la concordancia de características adyacentes.

[0086] El método SIMPAT puede ser ampliado en formas algo similares a las ampliaciones del método SNESIM. Así pues, al realizar una simulación en etapas que van desde una cuadrícula rugosa (por ejemplo, una cuadrícula que solo use cada quinto píxel en cada dirección) hasta una cuadrícula muy fina y utilizando los resultados de cada etapa previa (más rugosa) como los valores a encontrar en la siguiente etapa (más fina), el método SIMPAT mejora en gran medida la capacidad de encontrar la continuidad de características largas (tales como los canales). Asimismo, los patrones pueden ser escalados y rotados para satisfacer la información de escalación y rotación local. En general, el método SIMPAT alcanza mejores resultados que el método SNESIM (porque satisface las estadísticas de la imagen de entrenamiento original con más precisión) pero a nivel de cálculos es más lento.

[0087] En caso de que el criterio de estacionaridad del bloque 113 falle, la imagen de entrenamiento no estacionaria puede ser exportada como una cuadrícula de imagen para análisis geoestadístico de puntos múltiples (bloque 127A). Igualmente, la cuadrícula de orientación y los mapas de afinidad derivados como parte del cómputo de las estadísticas de estacionaridad pueden ser exportados como cuadrículas de limitación para análisis geoestadísticos de puntos múltiples que acepta imágenes de entrenamiento no estacionarias.

[0088] La metodología computarizada antes descrita puede aplicarse fácilmente a imágenes tridimensionales. Específicamente, el flujo de trabajo de la FIG. 1B sería modificado de la siguiente manera. Primero, los bloques 101-105 se adaptan para almacenar y recuperar imágenes tridimensionales.

52

Segundo, el bloque 107 se adapta para usar versiones tridimensionales de las operaciones de procesamiento de imágenes bidimensionales antes descritas a fin de procesar previamente imágenes tridimensionales y crear imágenes de entrenamiento tridimensionales válidas. Finalmente, el bloque 111 se adapta para usar versiones tridimensionales de las operaciones de procesamiento de imágenes bidimensionales antes descritas a fin de generar las estadísticas de estacionaridad. Más particularmente, en lugar de subdividir la imagen de entrenamiento bidimensional en 9 rectángulos superpuestos (FIGS. 6(A) – 6(I)), la imagen de entrenamiento tridimensional puede ser subdividida en 27 cubos superpuestos. Se utiliza una versión tridimensional de las operaciones que extraen el campo de orientación de la imagen de entrenamiento. En este caso, los primeros componentes principales de los vectores de orientación tridimensional son perpendiculares a las superficies de gradiente. Estos de orientación tridimensional son datos esféricos en los que se extraen las estadísticas de estacionaridad. Las versiones tridimensionales de las operaciones antes descritas para evaluar la estacionaridad del campo de orientación son descritas en Mardia, "Statistics of Discretional Data", Academic Press, New York, 1972, y en Rock, "Lecture Notes in Earth Sciences 18 – Numerical Geology", Springer Verlag, 1988, incorporados en su totalidad aquí por referencia. Las versiones tridimensionales de las operaciones antes descritas para acceder a la estacionaridad de escala también se utilizarían. En estas operaciones, las matrices de co-ocurrencia de niveles de gris que se utilizan requieren un sistema de adyacencia esférico y no uno circular. Las estadísticas de estacionaridad de escala se harían en mapas de afinidad escala-espacio tridimensionales empleando la versión tridimensional del SVD y la desviación estándar. Las estadísticas de estacionaridad de categorías pueden ejecutarse con facilidad en las distribuciones de categorías provenientes de los 27 cubos superpuestos de la imagen tridimensional (en lugar de los 9 rectángulos superpuestos de la imagen bidimensional). Los criterios de estacionaridad del bloque 113 serían igualmente aplicados para mantener o descartar imágenes de entrenamiento tridimensionales. Asimismo, las cuadrículas de imágenes de entrenamiento así como las cuadrículas de limitaciones de escala y orientación pueden ser exportadas como cuadrículas tridimensionales (en lugar de cuadrículas bidimensionales).

53

[0089] La metodología computarizada de la presente invención también puede ser aplicada con facilidad para trabajar con imágenes de entrenamiento que tienen valores continuo en lugar de un pequeño número de categorías. En consecuencia, la metodología es adecuada para métodos geoestadísticos de puntos múltiples que aceptan cuadrículas de imágenes de entrenamiento con valores de propiedad (en lugar de categorías).

[0090] Las metodologías computarizadas de la presente invención han sido probadas en una biblioteca de treinta y ocho imágenes de entrenamiento y se ha demostrado que identifican con precisión si la estacionaridad de una imagen de entrenamiento candidata la hace apropiada o no para realizaciones de MPGS. En consecuencia, los geólogos ahorran tiempo y evitan ejecutar realizaciones MPGS innecesarias al utilizar imágenes de entrenamiento inadecuadas. Asimismo, las metodologías computarizadas de la presente invención son computacionalmente eficientes y, por lo general, pueden ser llevadas a cabo en una computadora laptop convencional en sólo unos cuantos segundos, en tanto que uno debe esperar durante más tiempo por los resultados de una realización de algoritmos MPGS. Finalmente, se ha verificado cabalmente la producción de resultados estadísticos de estacionaridad mediante la metodología computarizada de la presente invención y se le ha encontrado similar a la resultado de una interpretación humana basada en una inspección visual de las imágenes de entrenamiento.

[0091] Han sido descritas e ilustradas aquí metodologías computarizadas para la evaluación automática de la estacionaridad de imágenes de entrenamiento para su uso en análisis geoestadísticos de puntos múltiples. Aun cuando se han descrito realizaciones específicas de la invención no es la intención que la invención se limite a dichas realizaciones sino que la invención sea tan amplia en alcance como lo permita la industria y que la especificación se leída de la misma manera. Por ello, apreciarán quienes conocen de la materia que aún pueden hacerse otras modificaciones a la invención presentada sin desviarse del espíritu y el alcance que se reivindican.

53

1. Un método implementado por computadora que consiste en:

analizar datos digitales que representan una imagen a fin de generar, por lo menos, una estadística que caracterice la estacionaridad de la imagen;

derivar, por lo menos, un puntaje basado en dicha estadística;

determinar si el puntaje satisface un criterio de estacionaridad; y

al determinar que el puntaje satisface el criterio de estacionaridad, almacenar o producir dicha imagen para usarla como cuadrícula de imagen de entrenamiento estacionaria en, por lo menos, un análisis geoestadístico de puntos múltiples.

2. Un método implementado por computadora según la reivindicación 1 en el que

dicha al menos una estadística consiste en una serie de estadísticas que caracterizan la estacionaridad de un campo de orientación extraído de la imagen.

3. Un método implementado por computadora según la reivindicación 2 en el que

Se calcula dicho campo de orientación derivando un campo de gradiente a través de convolución bidimensional en dicha imagen y luego extrayendo un componente principal del campo de gradiente sobre una ventana deslizante de tamaño fijo utilizando el análisis de componente principal.

4. Un método implementado por computadora según la reivindicación 3 en el que

la convolución bidimensional emplea filtros de Prewitt.

55

5. Un método implementado por computadora según la reivindicación 2 en el que

la serie de estadísticas que caracterizan la estacionaridad del campo de orientación comprende por lo menos uno de los siguientes: (i) un primer conjunto de estadísticas que caracterizan la no uniformidad del campo de orientación y, por ende, ofrece una indicación de que hay una o varias direcciones preferenciales en la cuadrícula de orientación, (ii) un segundo conjunto de estadísticas que caracterizan la normalidad de la distribución de direcciones en la cuadrícula de orientación y, por ende, ofrece una indicación de que hay una dirección dominante en el campo de orientación, y (iii) un tercer conjunto de estadísticas que caracterizan la repetibilidad del campo de orientación, lo cual ofrece una indicación de que el campo de orientación es similar en diferentes zonas de la imagen.

6. Un método implementado por computadora según la reivindicación 5 en el que

se calcula la serie de estadísticas sobre una serie de zonas superpuestas en la imagen.

7. Un método implementado por computadora según la reivindicación 5 que además comprende:

derivar un primer puntaje basándose en el primer conjunto de estadísticas;

derivar un segundo puntaje basándose en el segundo conjunto de estadísticas;

derivar un tercer puntaje basándose en el tercer conjunto de estadísticas; y

derivar un puntaje que caracterice la estacionaridad de orientación de la imagen basándose en primer, segundo y tercer puntajes.

55

56

8. Un método implementado por computadora según la reivindicación 7 en el que

el puntaje que caracteriza la estacionaridad de orientación de la imagen se calcula partiendo de un promedio ponderado del primer, segundo y tercer puntajes.

9. Un método implementado por computadora según la reivindicación 1 en el que

dicha al menos una estadística consiste en una serie de estadísticas que caracterizan la estacionaridad de escala de la imagen.

10. Un método implementado por computadora según la reivindicación 9 en el que

la serie de estadísticas que caracteriza la estacionaridad de escala de la imagen comprende las distancias entre un primer conjunto de vectores de características y un segundo conjunto de vectores de características, derivándose el primer conjunto de vectores de características de un primer conjunto de imágenes de desplazamiento generadas al someter la imagen a una serie de operaciones de muestreo dependientes de la rotación, y derivándose el segundo conjunto de vectores de características de un segundo conjunto de imágenes de desplazamiento generadas al someter un patrón de referencia seleccionado de la imagen a una serie de operaciones de muestreo dependientes de la rotación y la escala.

11. Un método implementado por computadora según la reivindicación 10 en el que

la serie de operaciones de muestreo dependientes de la rotación emplea el muestreo de adyacencia circular con transformaciones de orientación; y

la serie de operaciones de muestreo dependientes de la rotación y la escala emplea el muestreo de adyacencia circular con transformaciones de orientación y de escala.

56

12. Un método implementado por computadora según la reivindicación 11 en el que

las transformaciones de orientación se realizan en un número predeterminado de pares de factores de afinidad.

13. Un método implementado por computadora según la reivindicación 10 en el que

el primer conjunto de vectores de características se computa calculando las matrices de co-ocurrencia de niveles de gris en el primer conjunto de imágenes de desplazamiento; y

el segundo conjunto de vectores de características se computa calculando las matrices de co-ocurrencia de niveles de gris en el segundo conjunto de imágenes de desplazamiento.

14. Un método implementado por computadora según la reivindicación 10 que también comprende

generar un mapa de afinidad que caracteriza las distancias entre el primer conjunto de vectores de características y el segundo conjunto de vectores de características en la imagen de entrenamiento.

15. Un método implementado por computadora según la reivindicación 14 en el que

el mapa de afinidad identifica regiones de la imagen y una pareja de factores de afinidad en particular asociada con cada región dada, siendo la pareja de factores de afinidad en particular identificada al minimizar la distancia entre los vectores de características del primer conjunto correspondiente a la región dada y los vectores de características del segundo conjunto correspondiente a diferentes parejas de factores de afinidad.

16. Un método implementado por computadora según la reivindicación 14 en el que

57

57

58

el mapa de afinidad incluye submapas, cada uno de los cuales se corresponde con una pareja de factores de afinidad diferente, en el que un submapa dado caracteriza las distancias entre los vectores de características del primer conjunto y los vectores de características del segundo conjunto correspondiente a la pareja de factores de afinidad en particular del submapa dado.

17. Un método implementado por computadora según la reivindicación 16 en el que

cada submapa comprende una serie de píxeles en escala de grises.

18. Un método implementado por computadora según la reivindicación 16 en el que

cada submapa comprende una serie de píxeles binarios.

19. Un método implementado por computadora según la reivindicación 14 que además comprende

presentar el mapa de afinidad.

20. Un método implementado por computadora según la reivindicación 1 en el que

dicha al menos una estadística comprende una serie de estadísticas que caracteriza la estacionaridad de distribución de categoría de la imagen.

21. Un método implementado por computadora según la reivindicación 1 que además comprende

luego de determinar que el al menos un puntaje no satisface el criterio de estacionaridad, almacenar o producir la imagen para ser usada como una cuadrícula de imagen de entrenamiento no estacionaria en, por lo menos, un análisis geoestadístico de múltiples puntos.

22. Un método implementado por computadora según la reivindicación 2 que además comprende

58

almacenar o producir el campo de orientación para ser usado en, por lo menos, un análisis geoestadístico de múltiples puntos.

59

23. Un método implementado por computadora según la reivindicación 14 que

además comprende

almacenar o producir el mapa de afinidad para ser usado en, por lo menos, un análisis geoestadístico de múltiples puntos.

24. Un método implementado por computadora según la reivindicación 1 que además comprende

aplicar operaciones de procesamiento de imágenes a una imagen candidata a fin de generar una imagen adecuada para el análisis que genera, por o menos, una estadística que caracteriza la estacionaridad de la imagen, reduciendo dichas operaciones de procesamiento de imágenes el número de niveles en escala de grises/en color de la imagen candidata y a la vez manteniendo la importancia geológica de las categorías asignadas de la imagen candidata.

59

10






FIG.1A





3/39

4/39

**FIG.2A****FIG.2B**

5/39

64




FIG.2C




FIG.2D




FIG.2E

64



FIG. 3A



FIG. 3B




FIG. 3C



FIG. 3D

7/39

66




FIG.4

66

63

8/39




FIG. 5A




FIG. 5B




FIG. 6A




FIG. 6B




FIG. 6C




FIG. 6D




FIG. 6E




FIG. 6F




FIG. 6G




FIG. 6H




FIG. 6I

64




FIG.7A




FIG.7A
FIG.7B

FIG.7

FIG.7B

10/39

69




FIG.8




FIG.9

72




FIG.10A




FIG.10B

72

14/39




FIG.10C




FIG.10D

75

16/39

ESCALA X x0.5 ESCALA Y x2




FIG.10E

75

76

17/39




FIG.10F




FIG.10G

76

77

18/39




FIG.10H

77

19/39




FIG.10I

20/39




FIG.10J

ESCALA X x1. ESCALA Y x0.5




FIG.10K

ESCALA X x1. ESCALA Y x0.67




FIG.10L

22/39




FIG.10M

23/39




FIG.10N







FIG.100





ESCALA X x1.5. ESCALA Y x1.5







FIG. 10S

ESCALA X x1.5. ESCALA Y x2





29/39



ESCALA X x2. ESCALA Y x1





FIG.10W

89

ESCALA X x2. ESCALA Y x1.5



31/39

FIG.10X

ESCALA X x2. ESCALA Y x2





FIG.10Y

2

FIG.11



a3

34/39




FIG.12A




FIG.12C

98

94

35/39




FIG.12B

94

36/39






FIG.13



37/39

FIG.14

96






FIG.16A




FIG.16B

SUPERINTENDENCIA DE INDUSTRIA Y COMERCIO			
DIVISION DE NUEVAS CREACIONES			
TARJETA ARCHIVO PROPIETARIOS			
Industria y Comercio	SUPERINTENDENCIA		
PATENTE DE INVENCION ☒ PCT ☐ MODELO DE UTILIDAD ☐ DISEÑO INDUSTRIAL ☐			
(21) N° de solicitud:		(22) Fecha de solicitud: 13-07-06	
(51) Clasificación Internacional :			
(71) Solicitante(s)			
SCHLUMBERGER HOLDINGS LIMITED			
(72) Inventor(es) :			
Piotr MIROWSKI; Daniel TETZLAFF; David McCORMICK; Nneka WILLIAMS y Claude SIGNER			
(74) Apoderado: ALICIA LLORED A RICAURTE			
(30) Prioridad	(31) No. Prioridad	32) Fecha	(33) País
	11/180,191	13-07-05	US
(85) Fecha límite inicio fase nacional:		(87) Publicación internacional	
(86) Datos relativos a la presentación de la solicitud PCT		Fecha:	
Fecha de presentación de la solicitud:		N° publicación:	
No. de solicitud:			
(54) Título:			
GENERACION Y VALIDACION COMPUTARIZADA DE IMÁGENES DE ENTRENAMIENTO PARA ANALISIS GEOESTADISTICOS DE PUNTOS MULTIPLES			

SUPERINTENDENCIA DE INDUSTRIA Y COMERCIO						100
DIVISION DE NUEVAS CREACIONES						
TARJETA ARCHIVO TEMATICO						
Industria y Comercio		SUPERINTENDENCIA PATENTE DE INVENCION ☒ PCT ☐ MODELO DE UTILIDAD ☐ DISEÑO INDUSTRIAL ☐				
(21) N° de solicitud:		(22) Fecha de solicitud: 13-07-06				FIGURA CARACTERISTICA 6 x 6 cm
(51) Clasificación Internacional:						
(71) Solicitante(s)		SCHLUMBERGER HOLDINGS LIMITED				
(72) Inventor(es):		Piotr MIROWSKI; Daniel TETZLAFF; David McCORMICK; Nneka WILLIAMS y Claude SIGNER				
(74) Apoderado:		ALICIA LLOREDA RICAURTE				
(30) Prioridad	(31) No. Prioridad	(32)	Fecha	(33)	País	
	11/180,191		13-07-05		US	
(85) Fecha límite inicio fase nacional:		(87) Publicación internacional:				
(86) Datos relativos a la presentación de la solíc. PCT		Fecha:				
Fecha de presentación de la solicitud:		No. Publicación:				
No. de solicitud :						
(54) Título:						
GENERACION Y VALIDACION COMPUTARIZADA DE IMÁGENES DE ENTRENAMIENTO PARA ANALISIS GEOESTADISTICOS DE PUNTOS MULTIPLES						
(57) Resumen : <u>Reivindicación número 1.-</u>						
Un método implementado por computadora que consiste en:						
analizar datos digitales que representan una imagen a fin de generar, por lo menos, una estadística que caracterice la estacionaridad de la imagen;						
derivar, por lo menos, un puntaje basado en dicha estadística;						
determinar si el puntaje satisface un criterio de estacionaridad; y						
al determinar que el puntaje satisface el criterio de estacionaridad, almacenar o producir dicha imagen para usarla como cuadrícula de imagen de entrenamiento estacionaria en, por lo menos, un análisis geoestadístico de puntos múltiples.						
CONTINUA AL RESPALDO ...						

101



102
101

SUPERINTENDENCIA DE INDUSTRIA Y COMERCIO
Rad: 08-088235-00000-0000
Fec: 2008-07-13 10:57:40 Dep. 2020 NUECREACIONES
Tra: 2 PATENTES
Eve: 1 REGISTRO DE
17/11/08 PRESENTACION
Folios: 1/11

REQUISITOS MINIMOS PARA ADMISION A TRAMITE

PATENTE DE INVENCION [X]

MODELO DE UTILIDAD []

- ♦ Indicación de que se solicita la concesión de una patente [X] 1
- ♦ Datos de Identificación del solicitante o de la persona que presenta la solicitud [X] 1
- ♦ Descripción de la invención [X]
- ♦ Dibujos de ser estos pertinentes [X]
- ♦ Comprobante de pago de las tasas establecidas [X] 2

COMPLETA [X]

INCOMPLETA []

DISEÑO INDUSTRIAL []

- ♦ Indicación de que se solicita el registro de Diseño Industrial []
- ♦ Datos de Identificación del solicitante o de la persona que presenta la solicitud []
- ♦ Representación gráfica y fotográfica del Diseño Industrial o muestra del material que incorpora el diseño []
- ♦ Comprobante de pago de las tasas establecidas []

COMPLETA []

INCOMPLETA []

ESQUEMA DE TRAZADO []

- ♦ Indicación de que se solicita el registro de un Esquema de Trazado []
- ♦ Datos de identificación del solicitante o de la persona que presenta la solicitud []
- ♦ Representación gráfica del esquema trazado []
- ♦ Comprobante de pago de las tasas establecidas []

COMPLETA []

INCOMPLETA []


Firma Responsable

Fecha _____

Carrera 13 No. 27-00 Piso 5, 7 y 10
Conmutador: 3 82 08 40
Fax: 350 52 20
E-mail: info@sic.gov.co
www.sic.gov.co
Bogotá, D.C., Colombia

103
102

REPUBLICA DE COLOMBIA
SUPERINTENDENCIA DE INDUSTRIA Y COMERCIO

Bogotá,
2020

Doctor(a)
LLOREDA RICAURTE ALICIA

REFERENCIA	Radicación No. 6 68235
	Trámite 2
	Evento 1
	Actuación 430
	Oficio No. 7988

Como resultado del examen de forma, realizado con fundamento en el artículo 38 de la Decisión 486 de la Comisión de la Comunidad Andina, se le comunica que:


1. Debe allegar el poder otorgado al abogado que aparece en la solicitud como apoderado, con el lleno de los requisitos exigidos en el Código de Procedimiento Civil. Adicionalmente, deberá presentar el documento que acredita la existencia y representación legal de la sociedad solicitante.

2. Se recuerda al interesado que debe presentar, dentro de los dieciséis meses siguientes contados a partir de la fecha de presentación de la solicitud cuya prioridad se invoca, copia de la misma certificada por la autoridad que la expidió y, en los casos en que haya lugar, la traducción simple del capítulo reivindicatorio. El incumplimiento de éste plazo, acarreará la pérdida de la prioridad invocada.

3. Debe allegar copia del documento en que consta la cesión del derecho a la patente otorgado por el(los) inventor(s) al(los) solicitante(s) o a su(s) causante(s) (art. 26-k, Dec 486/2000).

En cumplimiento del artículo 39 de la Decisión 486, se le requiere para que dentro del término de dos (2) meses siguientes a la fecha de notificación del presente oficio, complete los requisitos anteriormente enunciados. En caso de no dar cumplimiento al presente requerimiento, la solicitud se considerará abandonada y perderá su prelación.

Notifíquese el presente oficio conforme a lo dispuesto en el numeral 5.2, literal e), del capítulo quinto del título primero de la Circular Unica No.10 de 2001.


ALIX CARMENZA CESPEDES DE VERGEL
Jefe de la división de Nuevas Creaciones

El anterior requerimiento fue notificado por fijación en lista de fecha 27 JUL 2006
adpa1