

06-68235

JOSE LLOREDA CAMACHO & CO.

Calle 72 No. 5-83 Piso 5, Bogotá, D.C. Tel: 6069700 Fax 6069701

103
SUPERINTENDENCIA DE INDUSTRIA Y COMERCIO
Rad: 06-068235-00002-0000
Fes: 2006-09-28 16:30:32 Dep. 2020 NUECREACIONES
Tra. 2 PATENTES
Evs: 1 REGDEPOSITO
Act 444 RESPUESTAREQUE Folios: 216

Señor

SUPERINTENDENTE DE INDUSTRIA Y COMERCIO

DIVISION DE NUEVAS CREACIONES

E. _____ S. _____ D. _____

Re: P1.-SCHLUMBERGER HOLDINGS LIMITED.-Solicitud de patente de invención para "GENERACION Y VALIDACION COMPUTARIZADA DE IMÁGENES DE ENTRENAMIENTO PARA ANALISIS GEOESTADISTICOS DE PUNTOS MULTIPLES".-Expediente número 06-068.235.-

1. Me refiero al auto dictado por ese Despacho y notificado por fijación en lista el 27 de Julio de 2006.

2. Con el fin de dar respuesta al requerimiento mencionado, estando dentro del término legal, me permito Informar a ese Despacho que la sociedad **SCHLUMBERGER TECHNOLOGY CORPORATION** cedió sus derechos a la sociedad **SCHLUMBERGER HOLDINGS LIMITED**.

En consecuencia, anexo me permito presentar a ese Despacho, copia debidamente legalizada del documento que acredita el contrato de cesión entre las sociedades **SCHLUMBERGER TECHNOLOGY CORPORATION** a **SCHLUMBERGER HOLDINGS LIMITED**, debidamente apostillado y junto con su Traducción Oficial No. 2006-09-14-595, debidamente legalizada hasta por el Ministerio de Relaciones Exteriores el 18 de Septiembre de 2006.

3. Teniendo en cuenta el anterior hecho, atentamente solicito a ese Despacho reconocerme personería en este asunto, de conformidad con el documento de Representación Legal para todos los asuntos de la

104

JOSE LLOREDA CAMACHO & CO.

Calle 72 No. 5-83 Piso 5, Bogotá, D.C. Tel: 8089700 Fax 8089701

Propiedad Industrial en Bogotá de la sociedad **SCHLUMBERGER HOLDINGS LIMITED**, otorgado a favor de la **SUSCRITA (ALICIA LLOREDA)** y/o al doctor GUSTAVO TAMAYO y/o al doctor IGNACIO SANTAMARIA y/o al doctor ENRIQUE ALVAREZ de acuerdo con la copia debidamente autenticada ante Notario Público que adjunto al presente expediente (Artículos 26 y 39 de la Decisión 486 de la Comunidad Andina de Naciones).

4. Con el texto del documento mencionado me permito presentar:

- (a) Documento que acredita a la SUSCRITA y/o al doctor GUSTAVO TAMAYO y/o al doctor IGNACIO SANTAMARIA y/o al doctor ENRIQUE ALVAREZ en los términos del parágrafo 1º. del Artículo 543 del Decreto-Ley 410 de 1971, como Representantes Legales en Bogotá para todos los asuntos relacionados con la propiedad industrial de la sociedad **SCHLUMBERGER HOLDINGS LIMITED**, una sociedad organizada y existente de conformidad con las leyes de Islas Vírgenes Británicas, domiciliada en Tortola, Islas Vírgenes Británicas; y
- (b) Traducción Oficial No. 2006-09-14-594 correspondiente a las partes pertinentes del documento anterior, también debidamente legalizado hasta por el Ministerio de Relaciones Exteriores el 18 de Septiembre de 2006.

5. Por otra parte, me permito presentar a ese Despacho:

- (a) Copia auténtica debidamente certificada de la solicitud de patente presentada para el invento arriba nombrado **respecto de la cual reclamo prioridad**, a saber la solicitud estadounidense número 11/180,191, junto con su traducción oficial número 2006-08-17-524, correspondiente a las legalizaciones y reivindicaciones de dicho documento; y

105

JOSE LLORED CAMACHO & CO.

Calle 72 No. 5-83 Piso 5, Bogotá, D.C. Tel: 6089700 Fax 6089701

- (b) Documento que acredita el traspaso que los autores del invento de la referencia hacen en favor de la sociedad **SCHLUMBERGER TECHNOLOGY CORPORATION**, organizada y existente bajo las leyes del Estado de Texas, de los derechos sobre el mismo, debidamente apostillado, junto con la Traducción Oficial número 2006-09-15-596, debidamente legalizada por el Ministerio de Relaciones Exteriores de Colombia, el 18 de Septiembre de 2006, correspondientes a dicho documento de traspaso.

6. Ruego a usted tomar atenta nota de lo anterior y proceder de conformidad.

Señor Superintendente,


ALICIA LLORED RICAURTE
T.P. 53.215

06-68235 106

TRADUCCION OFICIAL No. 2006-09-14-595
DE UN DOCUMENTO ESCRITO EN INGLES

Sello

El Estado de Texas
Secretario de Estado

APOSTILLA

(Convención de La Haya del 5 de octubre de 1961)

1. Pais: Estados Unidos de América
Este documento público
2. ha sido firmado por Kerry C Morris
3. actuando como Notario Público, Estado de Texas
4. y lleva el sello/estampilla de Kerry C Morris, Notario Público, Estado de Texas, La Comisión Expira: 04-21-10

CERTIFICADO

- | | |
|---|--------------------------------|
| 5. en Austin, Texas | 6. el día 14 de agosto de 2006 |
| 7. por el Secretario de Estado de Texas | |
| 8. Certificado No. N-545713 | |
| 9. Sello/Estampilla | 10. Firma: (ilegible) |
| Sello del Estado de Texas | Roger Williams |
| | Secretario de Estado |

TRADUCTORA OFICIAL
C. 2197/88 MINJUSTICIA

NELIA M. UBARDE TAMAYO

22586-20

NO SE ASUME
RESPONSABILIDAD DEL TEXTO

22 SEP 18 P 12:06
uds

JEFE DE LEGALIZACIONES
MINISTERIO DE GOBIERNO D.C.

MINISTERIO DE RELACIONES
EXTERIORES

DM
Señor

COYA FIRMA APARECE EN EL
DOCUMENTO OFICINA
LAS FIRMAS

TRASPASO DE PATENTE

El suscrito, **SCHLUMBERGER TECHNOLOGY CORPORATION**, una sociedad organizada y existente bajo las leyes del Estado de Texas, propietaria de la Solicitud de Patente de Colombia No. 06- 068.235, presentada el 13 de julio de 2006, mediante el presente transfiere y cede completamente los derechos correspondientes a dicha solicitud a **SCHLUMBERGER HOLDINGS LIMITED**, una sociedad organizada y existente bajo las leyes de las Islas Vírgenes Británicas, siendo dicho cesionario considerado desde ahora como el dueño y propietario único y legal del derecho sujeto.

SCHLUMBERGER HOLDINGS LIMITED mediante el presente acepta dicho traspaso y cesión.

EN TESTIMONIO DE LO CUAL, el documento presente es firmado por el presente el día 8 del mes de agosto de 2006.

SCHLUMBERGER TECHNOLOGY CORPORATION

POR: (firma: ilegible)

Nombre: Brigitte Jeffery Echols

Cargo: Apoderada para

SCHLUMBERGER TECHNOLOGY CORPORATION

EN TESTIMONIO DE LO CUAL, el documento presente es firmado por el presente el día 8 del mes de agosto de 2006.

SCHLUMBERGER HOLDINGS LIMITED

POR: (firma: ilegible)

Nombre: William B. Batzer

Cargo: Apoderada para

SCHLUMBERGER HOLDINGS LIMITED

CO 60.1621

Estado de Texas §

Condado de Fort Bend §

Suscrito y juramentado ante mí en este día 8 de agosto de 2006, por
Kerry C. Morris

Kerry C Morris
Mi Comisión Expira el 21 de abril de 2010

(firma: ilegible)

Notario Público en y para el Estado de
Texas

Mi comisión expira: 21 de abril de 2010

Estado de Texas §

Condado de Fort Bend §

Suscrito y juramentado ante mí en este día 8 de agosto de 2006, por
Kerry C. Morris.

Kerry C Morris
Mi Comisión Expira el 21 de abril de 2010

(firma: ilegible)

Notario Público en y para el Estado de
Texas

Mi comisión expira: 21 de abril de 2010

Traducido según mi mejor saber y entender, este día 14 de septiembre
de 2006, en la ciudad de Bogotá, D.C., por Anita Escobar de Tamayo,
Traductora Oficial, Res. 2177 de 1989, Ministerio de Justicia, República de
Colombia.

TRADUCTORA OFICIAL
RES. 2177/89 MINISTERIO DE JUSTICIA
Anita Escobar de Tamayo
ANITA ESCOBAR DE TAMAYO



199

The State of Texas

Secretary of State

APOSTILLE

(Convention de La Haye du 5 Octobre 1961)

1. Country: United States of America

This public document

2. has been signed by KERRY C MORRIS

3. acting in the capacity of Notary Public, State of Texas

4. and bears the seal/stamp of KERRY C MORRIS, Notary Public, State of Texas, Commission Expires: 04-21-10

CERTIFIED

5. at Austin, Texas

6. on August 14, 2006

7. by the Secretary of State of Texas

8. Certificate No. N-545713

9. Seal

10. Signature:



A handwritten signature in cursive script, reading "Roger Williams".

Roger Williams
Secretary of State
ST/sjs

110

PATENT ASSIGNMENT

The undersigned, **SCHLUMBERGER TECHNOLOGY CORPORATION**, a corporation organized and existing under the laws of the State of **Texas**, owner of Colombian Patent Application No. **06- 068.235**, filed on **July 13, 2006**, does hereby fully transfer and assign the rights corresponding to said application to **SCHLUMBERGER HOLDINGS LIMITED**, a corporation organized and existing under the laws of **British Virgin Islands**, the said assignee being considered from now as the sole and lawful owner and proprietor of the subject right.

SCHLUMBERGER HOLDINGS LIMITED, hereby accepts such transfer and Assignment.

IN WITNESS WHEREOF, the present document is hereby signed on the 8th day of the month of August the year 2006.

SCHLUMBERGER TECHNOLOGY CORPORATION

BY 


Name: Brigitte Jeffery Echols

Title: Attorney-in-Fact for

SCHLUMBERGER TECHNOLOGY CORPORATION

IN WITNESS WHEREOF, the present document is hereby signed on the 8th day of the month of August the year 2006.

SCHLUMBERGER HOLDINGS LIMITED

BY 

Name: William B. Batzer

Title: Attorney-in-Fact for

SCHLUMBERGER HOLDINGS LIMITED

;9409-047001

State of Texas
County of Fort Bend

§
§
§

Subscribed and sworn to before me on this 8th day of August, 2006, by Kerry C. Morris.




Kerry C. Morris
Notary Public in and for the State of Texas

My commission expires: April 21, 2010

State of Texas
County of Fort Bend

§
§
§

Subscribed and sworn to before me on this 8th day of August, 2006, by Kerry C. Morris.



Kerry C. Morris
Notary Public in and for the State of Texas

My commission expires: April 21, 2010

TRADUCCION OFICIAL No. 2006-09-14-594
DE UN DOCUMENTO ESCRITO EN INGLES

Sello

El Estado de Texas
Secretario de Estado

APOSTILLA

(Convención de La Haya del 5 de octubre de 1961)

1. País: Estados Unidos de América
Este documento público
2. ha sido firmado por Kerry C Morris
3. actuando como Notario Público, Estado de Texas
4. y lleva el sello/estampilla de Kerry C Morris, Notario Público, Estado de Texas, La Comisión Expira: 04-21-10

CERTIFICADO

- | | |
|--|---|
| 5. en Austin, Texas | 6. el día 24 de agosto de 2006. |
| 7. por el Secretario de Estado de Texas | |
| 8. Certificado No. N-547522 | |
| 9. Sello/Estampilla
Sello del Estado de Texas | 10. Firma: (ilegible)
Roger Williams
Secretario de Estado |

PODER

TRADUCTORA OFICIAL
NOTARY PUBLIC
NITANBUOBADE TAMAU

Legalización de un Poder de Representación Legal, documento escrito en inglés y en español.

(firma: ilegible)

Nombre: William B. Batzer

MINISTERIO DE RELACIONES
EXTERIORES

Anita
Esloba

CUYA FIRMA APARECE EN EL
DOCUMENTO DESEMPENA
LAS FUNCIONES DE

NO SE ASUME
RESPONSABILIDAD DEL TEXTO

2500 SEP 18 P 12:06

mas

UFF DE LEGALIZACIONES
BOGOTÁ D.C.

**Cargo: Apoderado para
SCHLUMBERGER HOLDINGS LIMITED**

Certificado Notarial (Sociedad), documento también escrito en inglés y en español.

**Estado de Texas
Condado de Fort Bend
(firma: ilegible)**

Notario Público

Fecha de Expiración de la Comisión: 21 de abril de 2010

**Kerry C Morris
Mi Comisión Expira el 21 de abril de 2010**

Traducido según mi mejor saber y entender, este día 14 de septiembre de 2006, en la ciudad de Bogotá, D.C., por Anita Escobar de Tamayo, Traductora Oficial, Res. 2177 de 1989, Ministerio de Justicia, República de Colombia.

**TRADUCTORA OFICIAL
"S. 2177/89 MINISTERIO DE JUSTICIA"
Anita Escobar de Tamayo
ANITA ESCOBAR DE TAMAYO**



The State of Texas

Secretary of State

APOSTILLE

(Convention de La Haye du 5 Octobre 1961)

1. Country: United States of America

**This public document
2. has been signed by**

KERRY C MORRIS

3. acting in the capacity of

Notary Public, State of Texas

4. and bears the seal/stamp of

**KERRY C MORRIS, Notary Public, State of
Texas, Commission Expires: 04-21-10**

CERTIFIED

5. at Austin, Texas

6. on August 24, 2006

7. by the Secretary of State of Texas

8. Certificate No. N-547522

9. Seal

10. Signature:



**Roger Williams
Secretary of State
ST/sjs**

647001

115

POWER OF ATTORNEY

Los abajo firmados, SCHLUMBERGER HOLDINGS LIMITED, una sociedad organizada y existente de conformidad con las leyes del Estado de

con domicilio en
P.O Box 71 Craigmuir Chambers Road Town, Tortola
British Virgin Islands.

con respecto a la solicitud colombiana de patente
No. 06.068.235

nombramos por el presente a ALICIA LLOREDA y/o GUSTAVO TAMAYO y/o IGNACIO SANTAMARIA y/o ENRIQUE ALVAREZ, domiciliados en Bogotá, Colombia, con oficinas en dicha ciudad, Calle 72 No. 5-83, piso 6o., nuestros representantes legales y verdaderos en Bogotá, con facultades para recibir notificaciones y nombrar apoderados judiciales o extrajudiciales, con el fin de dar cumplimiento al parágrafo 1o. del artículo 543 del decreto 410 de 1971.

Los doctores ALICIA LLOREDA y/o GUSTAVO TAMAYO y/o IGNACIO SANTAMARIA y/o ENRIQUE ALVAREZ, o los apoderados que cualquiera de ellos designe, quedan especialmente facultados para representarnos ante las autoridades colombianas, administrativas, judiciales o de policía, en todos los trámites relativos a la propiedad industrial, a cuyo efecto les facultamos para dar ante dichas autoridades todos los pasos necesarios al objeto indicado; elevar solicitudes, declaraciones, reclamos, recursos y presentar desistimientos; formular descripciones, enmiendas, limitar el alcance de las solicitudes, presentar oposiciones y apelaciones; instaurar cancelaciones, renunciar total o parcialmente a los registros, abonar todos los impuestos y cuotas y efectuar todo otro pago determinado por la ley; recibir todos los documentos y valores, dando el descargo respectivo; llenar cualesquiera otros requisitos y tomar, en fin, todas las medidas que creyeren conducentes al resguardo de nuestros intereses; y en caso de producirse oposición, pasando los antecedentes a los tribunales, quedan facultados para tomar intervención como demandantes o demandados ante los jueces que sean competentes, pudiendo transar, someter a árbitros, desistir, percibir y apelar, con todas las demás facultades que resulten necesarias, y por el presente declaramos desde ahora válido y bueno cuanto dichos representantes y/o los apoderados que cualquiera de ellos nombre hicieren en nuestro beneficio.

Asimismo, facultamos a los doctores ALICIA LLOREDA y/o GUSTAVO TAMAYO y/o IGNACIO SANTAMARIA y/o ENRIQUE ALVAREZ, para solicitar en la Oficina de Propiedad Industrial la protocolización de este documento y de cualquier poder que cualquiera de ellos otorgue a nombre nuestro.

Dado y firmado

The undersigned, SCHLUMBERGER HOLDINGS LIMITED, a corporation organized and existing under the laws of State of British Virgin Islands

domiciled at
P.O Box 71 Craigmuir Chambers Road Town,
Tortola, British Virgin Islands.

with respect to Colombian Patent Application
No. 06.068.235

hereby appoint, ALICIA LLOREDA and/or GUSTAVO TAMAYO and/or IGNACIO SANTAMARIA and/or ENRIQUE ALVAREZ, of Bogotá, Colombia, with offices in said town, Calle 72 No. 5-83, Sixth Floor, our true and legal representatives in Bogotá, with power to receive notifications and to appoint judicial or extrajudicial agents, so as to comply with paragraph 1o. of article 543 of decree 410 of 1971.

Doctors ALICIA LLOREDA and/or GUSTAVO TAMAYO and/or IGNACIO SANTAMARIA and/or ENRIQUE ALVAREZ, or the agents by any one of them appointed, are especially empowered to represent us before the administrative, judicial or police authorities of Colombia, in all proceedings pertaining to industrial property, for which purpose we authorize them to take before the said authorities all the necessary steps for the said end; to file petitions, declarations, claims, recourses and withdrawals, to draw up specifications; to file amendments, to limit the scope of applications, file oppositions; file cancellations total or partially waive registrations, to pay all installments and effect all other payments prescribed by law; to receive proper receipts, to comply with all other requirements and, in short, to take all those measures which they may deem fit for the protection of our interests; and in case of opposition, where the proceedings be passed over to the courts, we authorize said agents to act on our behalf, as complainants as well as defendants, before the competent judges, with full powers to make arrangements, to submit to arbitrators, to desist, to collect, to appeal and, in short, with all such further powers as may be required, and we hereby declare from now on as valid and good all that said representatives and/or the agents by any one of them appointed may do for our benefit.

We also authorize doctors ALICIA LLOREDA and/or GUSTAVO TAMAYO and/or IGNACIO SANTAMARIA and/or ENRIQUE ALVAREZ, to apply for protocolization of this document and of any power of attorney by any one of them conferred in our name, before the Office of Industrial Property.

Given and signed this 10th day of August, 2008



Name: William B. Batzer
Title: Attorney-in-Fact for
SCHLUMBERGER HOLDINGS LIMITED

CERTIFICADO NOTARIAL (SOCIEDAD)

Hoy 10 de Agosto
de 2008, compareció
William B. Batzer, a quien conozco y
de quien me consta que firmó el anterior documento, y quien
debidamente juramentado declaró y dijo que él es
Apoderado de SCHLUMBERGER HOLDINGS LIMITED
la compañía nombrada en el documento que antecede, una
sociedad debidamente organizada y existente conforme a
las leyes, domiciliada en la ciudad de Islas Virgenes
legalmente constituida para un período de duración que aún
no ha terminado, que ejerce su objeto social; conforme a las
leyes del Islas Virgenes Británicas, que el declarante está
autorizado por dicha Compañía para conferir este poder,
que el sello estampado por él al pie de tal poder, en nombre
y en representación de la expresada Compañía, es el sello
oficial de ella; y que el objeto para el cual se confiere esta
Instrumento está comprendido dentro del de la sociedad.
El suscrito Notario ha visto los Estatutos de Incorporación
firmados en _____
con fecha _____ y certifica que de
conformidad con la legislación de dicho Estado la anterior
declaración juramentada es prueba suficiente de que los
hechos sobre que ella versa son ciertos o verdaderos, de lo
cual da fe.

Notary Public (Notario Público).

SEAL

NOTARIAL CERTIFICATE (CORPORATION)

Country: United States of America
On this 10th day of August, 2008, personally
came William B. Batzer, to me known, and known to me to be
the person who signed the foregoing instrument, who being by
me duly sworn did depose and say that he is the
Attorney-in-Fact of SCHLUMBERGER HOLDINGS LIMITED,
the company named within, a Corporation organized and
existing under the laws of the British Virgin Islands,
legally constituted for a period of tenure not yet expired, which
exercises its corporate purposes according to the laws of the
State of British Virgin Islands; that the deponent
is authorized by said Company to confer this power of attorney;
~~that the seal affixed here unto by the deponent in the name~~
~~and on behalf of said Corporation is the corporate seal thereof;~~
and that the purpose for which this instrument is granted is
included within the corporate purposes of the Company.
~~The undersigned Notary Public has seen the articles of~~
~~incorporation of said Corporation executed at~~
~~_____ under~~
~~date of _____ and hereby~~
~~certifies that under the laws of said State the foregoing~~
~~acknowledgment is sufficient proof that the facts therein~~
~~contained are true, which he attests~~

State of TexasCounty of Fort Bend

Kerry C. Morris
Notary Public

Commission Expiration Date: April 21, 2010

LOS ESTADOS UNIDOS DE AMERICA

A QUIEN LA PRESENTE INTERESE

DEPARTAMENTO DE COMERCIO DE LOS ESTADOS UNIDOS

Oficina de Patentes y Marcas de Estados Unidos

Julio 10 de 2006

POR MEDIO DE LA PRESENTE CERTIFICAMOS QUE EL ANEXO ES UNA COPIA FIEL DE LOS REGISTROS DE LA OFICINA DE PATENTES Y MARCAS DE LOS ESTADOS UNIDOS DE LOS DOCUMENTOS DE LA SOLICITUD DE PATENTE IDENTIFICADA A CONTINUACION QUE CUMPLEN LOS REQUERIMIENTOS PARA CONCEDER UNA FECHA DE PRESENTACION BAJO 35 USC 111

NUMERO DE SOLICITUD: 11/180,191

FECHA DE PRESENTACION: Julio 13 de 2005

EL CODIGO DE PAIS Y NUMERO DE SU SOLICITUD DE PRIORIDAD, PARA SER USADA PARA PRESENTACION EN EL EXTERIOR BAJO LA CONVENCION DE PARIS ES US11/180,191

Por Autoridad de la

Secretaria de Comercio para Propiedad Intelectual y el Directos de La Oficina de Patentes y Marcas de Los Estados Unidos

Sello

Firma ilegible

N. WILLIAMS

Oficial Certificador

Departamento de Leyes de Propiedad Intelectual
 Schlumberger-Doll Research
 36 Old Quarry Road
 Ridgefield, CT 06877-4108
 Teléfono: (203) 431-5505
 Fax: (203) 431-5505
 e-mail: jdestefanis@ridgefield.oilfield.slb.com

Vía Correo Certificado No. EV 058 371 478 US
 Número de Cliente 37003

Julio 13 de 2005

Honorable Comisionado para Patentes
 P.O. Box 1450
 Alexandria, VA 22313-1450

Re: Nueva Solicitud de Patente de:
 Piotr MIROWSKI, Daniel TETZLAFF, David McCORMICK,
 Nneka WILLIAMS, Claude SIGNER,
 Titulada, "GENERACION Y VALIDACION DE IMÁGENES DE
 ENTRENAMIENTO BASADAS EN COMPUTADORA PARA ANALISIS
 GEOESTADISTICO DE MULTIPUNTO"
Nuestra Referencia No. 60.1621 US NP

Señor:

Adjunto, para la presentación en la Oficina de Patentes y Marcas de los Estados Unidos, está la nueva solicitud de patente identificada anteriormente, que incluye 42 páginas de texto, 6 páginas de reivindicaciones (1-24), Resumen, 35 hojas de dibujos (Fog.s 1-16B), y una Declaración no ejecutada.

El honorario de presentación se calcula de la siguiente forma:

Honorarios de Presentación Utilidad Básica	\$ 300.00
Honorarios de Búsqueda Utilidad Básica	\$ 500.00
Honorarios de Examen Utilidad Básica	\$ 200.00
Reivindicaciones Totales = <u>24</u>	
Exceso por encima de 20 (incluyendo Reediciones) = <u>4</u> x \$50.00	\$ 200.00

3 119

Reivindicaciones Independientes = <u>1</u>	
Exceso por encima de 3 (incluyendo Reediciones) = <u>0</u> x \$200.00	\$
Hojas Totales de Solicitud = <u>84</u>	
Exceso por encima de 100 = ____ x \$250/50 hojas o fracciones de hoja	\$
Honorarios Totales	\$ 1,200.00

Respetuosamente se solicita que se asigne una fecha de presentación del día de hoy a esa solicitud de acuerdo con 37 CFR §§1.10 y 37 CFR §§1.53, que permite presentación por Correo Expreso y posterior presentación de la Declaración Juramentada, respectivamente.

El Comisionado autoriza por medio de la presente cargar en la Cuenta No. 19-0615 la cantidad de \$1200.00 para cubrir los honorarios calculados anteriormente y cualquier otro honorarios que pueda ser requerido bajo 37 C.F.R. § 1.16. Si la cantidad es incorrecta, por medio de la presente el Comisionado autoriza a cargar o debitar cualquier deficiencia o sobrepago a la Cuenta No. 019-0615.

Se adjuntan dos copias de esta carta de transmisión para uso de contabilidad de la PTO.

Atentamente,

Firma ilegible

Jody Lynn DeStefanis

No. de Registro 44,653

EN LA OFICINA DE PATENTES Y MARCAS DE LOS ESTADOS UNIDOS

En Solicitud re de
MIROWSKI, Piotr et al.

» NUMERO DE CLIENTE 37003
» Grupo de Unidad de Arte:
» Desconocido
» Examinador: Desconocido

Serial No.: A ser asignado

Presentada: Julio 13 de 2005

Para: **GENERACION Y VALIDACION DE** Expediente de Representación
IMÁGENES DE ENTRENAMIENTO No. 60.1621 US NP
BASADAS EN COMPUTADORA PARA
ANALISIS GEOESTADISTICO DE
MULTIPUNTO

CERTIFICADO DE CORREO EXPRESO
BAJO 37 CFR § 1.10

Honorable Comisionado para Patentes
P.O. Box 1450
Alexandria, VA 22313-1450

Señor:

Número de Guía de Correo Certificado No. EV 058 371 478 US
Fecha de Depósito: JULIO 13 DE 2005

Por medio de la presente certifico que el(los) documento(s) adjuntos están siendo depositados en el Servicio Postal de los Estados Unidos bajo el servicio "Oficina de Correo Expreso a destinatario" bajo 37 CFR. § 1.10, en la fecha indicada anteriormente, y está dirigido al Comisionado para Patentes, P.O. Box 1450, Alexandria, VA 22313-1450.

(Firma) Firma ilegible
(Nombre impreso) Ruth A. Schrelber

Schlumberger-Doll Research
Departamento de Leyes de PI
36 Old Quarry Road
Ridgefield, Conneticut 06877-4108
(203) 431-5505

5/ 121

EXPEDIENTE DE REPRESENTACION No. 60.1621 US NP
NUMERO DE CLIENTE 37003

SOLICITUD DE PATENTE

GENERACION Y VALIDACION DE IMÁGENES DE ENTRENAMIENTO BASADAS EN COMPUTADORA PARA ANALISIS GEOESTADISTICO DE MULTIPUNTO

Inventores:

MIROWSKI, Piotr, un ciudadano de Francia, residente en 25 Indian Road, Apt. 1E, New York, New York 10034, USA:

TETZLAFF, Daniel, un ciudadano de los Estados Unidos de América, residente en 9538 Beverlyhill Street, Houston, Texas, 77063, USA:

McCORMICK, David, un ciudadano de los Estados Unidos de América, residente en 18 Bromfield Road, Acton, Massachussetts 01720, USA;

WILLIAMS, Nneka, un ciudadano de los Estados Unidos de América, residente en 255 Massachussetts Avenue, Apt. 709, Boston, Massachussetts 02115, USA

SIGNER, Claude, un ciudadano de Francia, residente en 265 Willow Avenue, Somerville, Massachussetts 02115, USA

Cesionario: SCHLUMBERGER TECHNOLOGY CORPORATION

Con oficinas en:

36 Old Quarry Road.

Ridgefield, CT 06877-4108

Constituida en el Estado de Texas

Dirección de Correspondencia:

SCHLUMBERGER-DOLL RESEARCH

Intellectual Property Law Department

122

36 Old Quarry Road
Ridgefield, CT 06877-4108

GENERACION Y VALIDACION DE IMÁGENES DE ENTRENAMIENTO BASADAS EN COMPUTADORA PARA ANALISIS GEOESTADISTICO DE MULTIPUNTO

ANTECEDENTES DE LA INVENCION

Campo de la Invención

Esta invención se relaciona ampliamente con análisis estadístico de variables aleatorias que simulan un campo de propiedad. Más particularmente, esta invención se relaciona con métodos geoestadísticos multipunto y simulaciones.

Estado de la Técnica

La Geoestadística es una disciplina relacionada con variables aleatorias distribuidas espacialmente (también llamadas "variables regionalizadas"), usualmente aplicadas a problemas en las ciencias de la tierra, tales como estimación de reservas minerales y delineación de depósitos de minerales, depósitos de hidrocarburos, y acuíferos. La geoestadística de multipunto (o de punto múltiple) (MPGS) se diferencia del resto de la geoestadística principalmente en que caracteriza la variabilidad espacial usando patrones (conjuntos de puntos) que contienen más de dos puntos.

Una de las metas de la geoestadística de multipunto es la simulación, a saber, la generación de valores numéricos a lo largo de una línea, en una superficie, o en volumen, de forma que el conjunto de valores replique ciertas propiedades de correlación espacial dadas (usualmente derivadas de un conjunto de datos llamado "análogo" o "imagen de entrenamiento") mientras que replica opcionalmente (en el caso llamado "simulación condicional") datos predeterminados. En la práctica, el "análogo" puede ser, por ejemplo, un volumen de roca bien conocido que es estadísticamente similar a un depósito de petróleo pobremente conocido que está siendo delineado, y los datos predeterminados a ser replicados pueden ser observaciones de litología en

pozos, o probabilidades de litologías derivadas de datos sísmicos. De esta forma, las simulaciones de MPGS replican restricciones absolutas o llamadas "duras" a partir de los datos adquiridos en los pozos o afloramientos, y restricciones condicionales o "blandas" a partir de datos sísmicos, campos de probabilidad de facies, y cuadrículas de restricción de rotación y afinidad (o escala). Tales datos se usan en un proceso de modelamiento estocástico para generar mapas unidimensionales (1D), bidimensionales (2D) y/o tridimensionales (3D) de facies geológicas o propiedades de roca. Como hay un componente aleatorio involucrado en las simulaciones de MPGS, las realizaciones individuales de campos de propiedad creados mediante algoritmos de MPGS difieren, pero el grupo de realizaciones provee a los geocientíficos e ingenieros de depósitos con estimados cuantitativos mejorados de la distribución espacial e incertidumbre de facies geológicas o propiedades de roca en un volumen de depósito modelado.

Recientemente se ha demostrado que métodos geoestadísticos de multipunto son computacionalmente factibles y han sido probados en conjuntos de datos reales como se indica en i) Strebelle, "conditional Simulation of complex geological structures using multiple-point statistics", *Mathematical Geology*, v.34, n. 1, 2002, pp- 1-22, ii) Strebelle et al., "Modeling of a deepwater turbidite reservoir conditional to seismic data using principal component analysis and multiple-point geostatistics", *SPE Journal*, Vol. 8, No. 3, 2003, pp. 227-235, y iii) Liu et al., "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.

Los métodos geoestadísticos tradicionales se basan en un variograma para describir la continuidad geológica. Sin embargo, un variograma, que es una medida de dos puntos de variabilidad espacial, no puede describir patrones realistas curvilíneos o geoméricamente complejos. Los métodos geoestadísticos de multipunto usan una imagen de entrenamiento (en lugar de un variograma) para proporcionar información geológica. La imagen de entrenamiento provee una descripción conceptual de la heterogeneidad geológica de la sub-superficie, que contiene posiblemente patrones de multipunto complejos de heterogeneidad geológica. La simulación estadística de multipunto ancla estos patrones a los datos de pozos (y/o datos de afloramientos y a la información derivada de la sísmica (y/o la información de campo de probabilidad o cuadrícula(s) de restricción).

La imagen de entrenamiento usualmente, pero no necesariamente, tiene una baja resolución (i.e., típicamente unos pocos de píxeles por 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 a color) asociado con este. El nivel de cada píxel se refiere aquí como una categoría. Típicamente, hay alrededor de 5 a 10 categorías posibles en cada píxel de la imagen de entrenamiento, pero este número podría ser mayor o menor. Las formas del (los) elemento(s) geológicos definidos por la imagen de entrenamiento representan un modelo de elementos geológicos reales, cada categoría representa típicamente una facies geológica diferente o una clase diferente de cuerpo geológico.

La geoestadística se basa en el concepto bien conocido de variables aleatorias. En términos simples, las propiedades del depósito en diferentes ubicaciones de la cuadrícula son en gran medida desconocidas o inciertas; así, cada propiedad de interés en cada ubicación de cuadrícula se vuelve una variable cuya variabilidad se describe mediante una función de probabilidad. Con el fin de realizar cualquier tipo de simulación estadística, se requiere una decisión o suposición de estacionariedad. En los métodos geoestadísticos de multipunto, el uso de imágenes de entrenamiento está enlazado por el principio de estacionariedad descrito por Caers et al., "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 modelamiento de depósitos en 2D o 3D, se dice que una variable aleatoria o proceso aleatorio es estacionario si todos sus parámetros estadísticos son independientes de su ubicación en el espacio (invariante de acuerdo a cualquier traslación). En el caso de imágenes de entrenamiento, esta estacionariedad puede consistir, pero no se limita a:

- estacionariedad de orientación, cuando los elementos direccionales no rotan a lo largo de la imagen de entrenamiento; y
- estacionariedad de escala (cuando el tamaño de los elementos en la imagen no cambia a lo largo de la imagen de entrenamiento).

Aunque el concepto de estacionariedad es referido en Caers et al., artículo titulado "Multiple-point geostatistics; a quantitative vehicle for integrating

geologic analogs into multiple reservoir models", este artículo falla en revelar una metodología para estimar y validar automáticamente la estacionariedad de una imagen de entrenamiento dada para asegurar que esa imagen de entrenamiento es apropiada para los métodos geoestadísticos de multipunto.

RESUMEN DE LA INVENCION

Por lo tanto, un objeto de la invención es proveer una metodología para estimar y validar automáticamente la estacionariedad de una imagen de entrenamiento dada para asegurar que la imagen de entrenamiento es apropiada para los métodos geoestadísticos de multipunto.

Otro objeto de la invención es proveer estructuras de datos que caractericen propiedades de una imagen de entrenamiento, que se puede usar en los métodos geoestadísticos de multipunto.

De acuerdo con estos objetos, que serán discutidos en detalle a continuación, se provee un método implementado por computadora que caracteriza y verifica automáticamente la estacionariedad de una imagen de entrenamiento para uso en análisis geoestadístico de multipunto. La estacionariedad de la imagen de entrenamiento es preferiblemente caracterizada por medidas estadísticas de estacionariedad de orientación, estacionariedad de escala, y estacionariedad de distribución de categoría.

Se apreciará que los métodos implementados por computadora de la presente invención proveen una determinación automática y precisa si una imagen de entrenamiento candidata es estacionaria y, de esta forma, es adecuada para realizaciones de MPGS que requieren tales imágenes de entrenamiento estacionarias. En consecuencia, los geólogos que emplean los métodos implementados por computadora de la presente invención ahorran tiempo y evitan correr realizaciones de MPGS innecesarias usando imágenes de entrenamiento no adecuadas.

De acuerdo con una realización preferida de la invención, las medidas estadísticas que caracterizan la estacionariedad de orientación de la imagen de entrenamiento incluyen al menos una de las siguientes: (i) un primer conjunto de estadísticas que caracterizan la no uniformidad del campo de orientación y

provee así una indicación 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 provee así una indicación 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, que provee una indicación que el campo de orientación es similar a lo largo de diferentes zonas de la imagen. Las medidas estadísticas que caracterizan la estacionariedad de escala de la imagen de entrenamiento incluyen preferiblemente distancias entre un primer conjunto de vectores de característica y un segundo conjunto de vectores de características. El primer conjunto de vectores de características se deriva de un primer conjunto de imágenes de desplazamiento que son generadas al someter la imagen a una pluralidad de operaciones de muestreo dependientes de la rotación. El segundo conjunto de vectores de característica es deriva de un segundo conjunto de imágenes de desplazamiento que son generadas al someter un patrón de referencia seleccionado de la imagen a una pluralidad de operaciones de muestreo dependientes de la rotación y la escala.

Objetos y ventajas adicionales de la invención serán obvias para los expertos en la técnica al referirse a la descripción detallada tomada en conjunción con la Figuras proporcionadas.

BREVE DESCRIPCION DE LOS DIBUJOS

La FIG. 1(A) es un diagrama de bloque de un sistema de procesamiento de computadora que incorpora la metodología de la presente invención.

La FIG. 1(B) es un diagrama de flujo que ilustra el flujo de trabajo de la metodología basada en computadora para la generación y verificación automática de las imágenes de entrenamiento y posterior análisis geoestadístico de multipunto basado en este, de acuerdo con la presente invención.

Las FIGS. 2(A) – 2(E) son una secuencia de imágenes que ilustran las operaciones de procesamiento de imagen realizadas a 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 de un delta de río.

Las FIGS. 3(A) – 3(D) son una secuencia de imágenes que ilustran las operaciones de procesamiento de imagen 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 la imagen de entrenamiento; la FIG. 3(B) es una imagen que ilustra el componente Y del campo de gradiente 2D que es generado al aplicar el filtro de Prewitt G_y sobre la categoría de imagen 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 es generado al aplicar el filtro de Prewitt G_x sobre la categoría de imagen 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 imagen de entrenamiento de la FIG. 3(A).

La FIG. 4 es un diagrama de flujo que ilustra las operaciones que generan estadísticas de estacionariedad de orientación y un puntaje basado en estas como parte del flujo de trabajo de la FIG. 1(B).

Las FIGS. 5(A) y 5(B) son gráficas que ilustran la probabilidad de función de densidad de una distribución de Von Mises.

Las FIGS. 6(A) – 6(I) son diagramas que ilustran la partición de una categoría de imagen de entrenamiento en zonas de superposición; estas zonas de superposición se usan en el cálculo de las estadísticas de estacionariedad de orientación (y un puntaje basado en estas), de estadísticas de estacionariedad de escala (y un puntaje basado en estas), y de las estadísticas de estacionariedad de distribución de categoría (y un puntaje basado en estas) como parte del flujo de trabajo de la FIG. 1(B).

La FIG. 7 es un diagrama de flujo que ilustra las operaciones que generan estadísticas de estacionariedad de escala y un puntaje basado en estas, como parte del flujo de trabajo de la FIG. 1(B).

La FIG. 8 es una gráfica que ilustra un sistema de muestreo de vecindad de 4º orden circular.

La FIG. 9 es una gráfica que ilustra un sistema de muestreo de vecindad de 4º orden circular adaptado para el muestreo dependiente de la rotación y la escala, el sistema de muestreo dependiente de la rotación se usa para

muestrear la imagen de entrenamiento y extraer los vectores de característica de la imagen de entrenamiento; el muestreo dependiente de la rotación y la escala se usa para muestrear un patrón de referencia y extraer los vectores de característica del patrón de referencia; estos vectores de característica son analizados para generar las estadísticas de estacionariedad de escala y un puntaje pasado en ellas, como parte del flujo de trabajo de la FIG. 1(B).

Las FIGS. 10(A) – 10(Y) son diagramas que ilustran un conjunto de 25 parejas de factor de afinidad; estas parejas de factor de afinidad se usan para calcular las estadísticas de estacionariedad de escala y un puntaje basado en estas, como parte del flujo de trabajo de la FIG. 1(B).

La FIG. 11 es un diagrama esquemático que ilustra las operaciones que calculan las estadísticas de estacionariedad de escalas y un mapa de afinidad basado en estas como parte del flujo de trabajo de la FIG. 1(B).

La FIG. 12(A) es una imagen de entrenamiento ejemplar, que se deriva copiando/pegando la esquina superior izquierda (indicada por un rectángulo) en las otras partes de la imagen con diferentes transformaciones de afinidad aplicadas a esta.

La FIG. 12(B) es un conjunto de mapas de afinidad que ilustran la distancia entre los vectores de característica para partes correspondientes en la imagen de entrenamiento y el patrón de referencia sobre diferentes parejas de factor de afinidad para la imagen de entrenamiento de la FIG. 12(A) con la esquina superior izquierda como el patrón de referencia; los píxeles de cada imagen 2D están en escala de grises con las distancias representadas por los píxeles cuantificados en un rango de valores de escala de grises.

La FIG. 12(C) es un conjunto de mapas de afinidad que ilustran la distancia entre los vectores de característica para partes correspondientes en la imagen de entrenamiento y el patrón de referencia sobre diferentes parejas de factor de afinidad para la imagen de entrenamiento de la FIG. 12(A) con la esquina superior izquierda como el patrón de referencia; los píxeles de cada imagen 2D son binarios con las distancias representadas por los píxeles asignados a un rango binario de valores; las distancias más cercanas son asignadas a un valor binario (p.e., negro), mientras que las otras distancias son asignadas al otro valor binario (p.e., blanco).

La FIG. 13 es una gráfica que ilustra la medida de una distribución de puntos en un espacio bidimensional; esta medida se usa para calcular las estadísticas de estacionariedad de escala y un puntaje basado en estas como parte del flujo de trabajo de la FIG: 1(B).

La FIG. 14 es un diagrama que ilustra una gráfica tri-dimensional de los puntajes de estacionariedad para un número de imágenes de entrenamiento; los ejes corresponden a tres medidas de estacionariedad diferentes, el eje X corresponde a la medida de estacionariedad de distribución de categoría, el eje Y corresponde a la medida de estacionariedad de escala, y el eje Z corresponde a la medida de estacionariedad de orientación; las regiones de este espacio 3-D se pueden definir como delimitadoras de "buenas" imágenes de entrenamiento y se usan como un criterio de decisión para evaluar automáticamente si la imagen de entrenamiento particular es suficientemente estacionaria para uso en análisis geoestadísticos de multipunto que requieren tal estacionariedad.

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

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

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

DESCRIPCION DETALLADA DE LA REALIZACION PREFERIDA

La FIG. 1(A) es un diagrama de bloque funcional de un sistema de computadora de propósito general 100 que incorpora la presente invención. El sistema de computadora 10 puede incluir una estación de trabajo (o computadora personal de alto desempeño) que realiza los cálculos relevantes y decisión lógica discutida más adelante, e.g., procesamiento de imagen de entrenamiento, generación y evaluación de estadísticas de estacionariedad de la imagen de entrenamiento, y análisis estadístico de multipunto basado en estas. Por ejemplo, el sistema de computadora 10 puede incluir un dispositivo

de representación 12 y dispositivos de entrada de usuario tales como teclado 14 y mouse 16. El sistema de computadora 10 incluye también memoria 18 (e.g., memoria persistente tal como una unidad de disco dura magnético, así como una memoria no persistente tal como uno o más módulos DRAM) que almacenan aplicación(es) de software que son ejecutadas en un procesador 20 para realizar los cálculos relevantes y la discusión lógica discutida más adelante, e.g., procesamiento de imagen de entrenamiento, generación y evaluación de estadísticas de estacionariedad de la imagen de entrenamiento, y análisis estadístico de multipunto basado en estas. Tales aplicaciones de software, que comprenden una secuencia programada de instrucciones y datos, se almacenan típicamente en uno o más discos ópticos que son cargados en la memoria 18 mediante una unidad de disco óptico (no mostrada) para almacenamiento persistente allí. Alternativamente, tales aplicaciones de software pueden ser cargadas en la memoria 18 sobre una conexión de red (e.g., una conexión de Internet) u otro medio adecuado para almacenamiento persistente allí. En la siguiente descripción, la "imagen" se refiere indistintamente a una línea o una superficie o un volumen, y consiste de una distribución continua de píxeles iguales, cada uno de los cuales puede contener un valor (o número).

La FIG. 1(B) ilustra un flujo de trabajo que incorpora una metodología basada en computadora para la generación automática y la validación de imágenes de entrenamiento y simulaciones geoestadísticas de multipunto basadas en estas, de acuerdo con la presente invención. Las imágenes candidatas que se usan para la generación de imágenes de entrenamiento son almacenadas en una base de datos de imagen 101, que se puede relizar mediante cualquier clase de almacenamiento electrónico, óptico o magnético. En el bloque 103, una imagen candidata es importada de la base de datos de imagen 101. En este punto, la imagen candidata puede ser de cualquier clase de negro y blanco, escala de grises, color o imagen multiespectral, y puede ser de cualquier definición (resolución). Para simplicidad de la descripción, la imagen candidata es referida como una imagen de "alta resolución" en el bloque 105.

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 se desea, y ajustar su resolución si se desea. Los métodos geoestadísticos de multipunto requieren una imagen de entrenamiento con un número pequeño de categorías,

por ejemplo de menos de 11. Usualmente, las dimensiones de la imagen de entrenamiento deben ser de unos pocos cientos de píxeles por lado. La tarea de reducir el número de niveles de escala de grises/color de la imagen candidata mientras se mantiene la significancia geológica de las categorías asignadas de la imagen candidata es de dificultad variable y depende de la complejidad y calidad de la imagen candidata, incluyendo la presencia de ruido y los efectos de iluminación. La lista de operaciones de procesamiento de imagen que se pueden usar como parte de este paso incluyen, pero no se limitan a, operaciones de morfología matemática en imágenes, umbrales o agrupamiento de histograma de color o nivel de gris, filtro de imagen de paso bajo o paso alto. Usualmente, el resultado deseado puede ser alcanzado solamente a través de una combinación de operaciones sucesivas de procesamiento de imagen en la imagen original. Se puede proveer una interfaz de usuario gráfica que habilite a un usuario para interconectarse con tales bloques, visualizar tales interconexiones mediante una gráfica, y luego guardar el flujo de trabajo de procesamiento de imagen interconectada para uso posterior. La imagen resultante generada por el flujo de trabajo de procesamiento de imagen del bloque 107 se refiere como una imagen de entrenamiento de "baja resolución, poca categoría" en el bloque 109. Las dimensiones y categorías de la imagen de entrenamiento del bloque 109 coinciden con las dimensiones y categorías requeridas para los métodos geoestadísticos de multipunto posteriores (bloque 119).

Las FIGS. 2(A) – 2(E) ilustran un ejemplo del flujo de trabajo de procesamiento de imagen del bloque 107 en una imagen candidata que es una fotografía aérea a color de un delta de un río. La FIG. 2(A) es la copia en escala de grises de la fotografía aérea a color. La FIG. 2(B) es el resultado de la remoción del efecto de iluminación en la imagen de la FIG. 2(A) mediante la aplicación de una operación morfológica. La FIG. 2(C) es el resultado de una segmentación de color de la imagen de la FIG. 2(B) y de la remoción de áreas grandes conectadas (aquí el río y el mar) mediante una técnica de inundación-llenado. 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 están fusionados. La FIG. 2(E) es un resalto afluado de la imagen de la FIG. 2(D) y muestra el patrón del canal del río que es retenido para el propósito de una imagen de entrenamiento candidata para los métodos geoestadísticos de multipunto. Este patrón tiene 2 categorías, el río y el fondo.

En el bloque 111 se estima la estacionariedad de la imagen de entrenamiento del bloque 109. Tales operaciones derivan estadísticas de estacionariedad que caracterizan la estacionariedad de la imagen de entrenamiento. Preferiblemente, tales estadísticas caracterizan la estacionariedad del campo de orientación (bloque 111A), la estacionariedad de la escala de imagen (bloque 111B) y la estacionariedad de la distribución de categorías (bloque 111C) para la imagen de entrenamiento del bloque 109.

En el bloque 113, las estadísticas de estacionariedad derivadas en el bloque 111 son analizadas para determinar si la imagen de entrenamiento del bloque 109 satisface un conjunto de restricciones predeterminadas que dictan si la imagen de entrenamiento debe o no usarse en análisis geoestadístico de multipunto posterior (e.g., bloque 119). Si las estadísticas de estacionariedad satisfacen tales restricciones predeterminadas, la imagen de entrenamiento es agregada a una base de datos de imagen de entrenamiento 115, que se puede realizar mediante cualquier clase de almacenamiento electrónico, óptico o magnético. Se puede acceder a esta imagen de entrenamiento desde la base de datos 115 (o salida directamente del bloque 113) para uso en un análisis geoestadístico de multipunto (bloque 119). Tales operaciones pueden involucrar formatear la imagen de entrenamiento como una cuadrícula de imagen de entrenamiento (bloque 117) de acuerdo con el formato requerido por el análisis geoestadístico de multipunto (bloque 119).

Si en el bloque 113 se determina que las estadísticas de estacionariedad no satisfacen las restricciones predeterminadas, el usuario selecciona si la imagen de entrenamiento no estacionaria debe ser agregada a la base de datos de imágenes de entrenamiento 115 (bloque 121) o descartada (bloque 123). Se puede acceder la imagen de entrenamiento no estacionaria desde la base de datos 115 (o salida directamente del bloque 121) para uso en el análisis geoestadístico de multipunto (bloque 127). Tales operaciones pueden utilizar la imagen de entrenamiento no estacionaria como la base para una cuadrícula de imagen de entrenamiento no estacionaria (bloques 125A, 127A), una cuadrícula de restricción de escala (bloques 125B, 127B), o una cuadrícula de restricción de orientación (bloques 125C, 127C).

Para las imágenes no estacionarias (e.g., aquellas no descartadas en el bloque 123), las operaciones pueden recursivamente brincar al bloque 107, en donde las diferentes técnicas de procesamiento de imágenes pueden ser

aplicadas para extraer otras características de la imagen candidata del bloque 105 con el fin de producir una imagen de entrenamiento que cumple los criterios de estacionariedad (bloques 109-113).

La FIG. 4 ilustra las operaciones del bloque 111A que caracterizan la estacionariedad del campo de orientación de la imagen de entrenamiento del bloque 109. Se asume que para cada imagen de entrenamiento, las categorías de la imagen de entrenamiento corresponden a diferentes elementos geológicos. Con el fin de separar las estadísticas de estacionariedad de orientación por categoría y por clase de elemento geológico, cada categoría es aislada y el campo de orientación y las estadísticas derivadas de estas, se derivan para la categoría particular. Con el fin de aislar una categoría particular, los píxeles que son de cualquier 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 significancia que el usuario quiere atribuirles.

Las operaciones en la imagen de entrenamiento (marcadas bloque 401) empiezan por inicializar un contador (variable "k") a 1 (bloque 403) y luego transformar una copia de la imagen de entrenamiento de forma que la categoría correspondiente al contador k (i.e., la categoría k^a) es aislada de las otras categorías (bloque 405). Esta imagen es referida como una "categoría de imagen de entrenamiento" más adelante.

En los bloques 407 y 409 se deriva el campo de orientación para la categoría de imagen de entrenamiento. En la realización preferida, el campo de orientación es calculado primero computando el campo de gradiente de la categoría de imagen de entrenamiento usando una convolución en 2D, tales como los filtros de Prewitt "vertical" y "horizontal", y luego extrayendo el primer componente principal del campo de gradiente sobre una ventana deslizante de tamaño fijo (que es referido como el "kernel") usando análisis de componente principal. Tales análisis se describen en detalle en FENA X., "Analysis and Approaches to Image Local Orientation Estimation", tesis presentada para un Msc en Ingeniería de Computadoras en la Universidad de California en Santa Cruz, 2003, y en Randen et al., "Three-Dimensional Textura Attributes for Seismic Data Analysis", Schlumberger Stavanger Research, SEG 2000 Expanded Abstracts, 2000, incorporada aquí para referencia en su totalidad. El filtro de Prewitt "vertical"

$$G_x = \begin{bmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{bmatrix},$$

enfatisa bordes "horizontales" (i.e., bordes a lo largo de la

$$G_y = \begin{bmatrix} 1 & 0 & -1 \\ 1 & 0 & -1 \\ 1 & 0 & -1 \end{bmatrix}$$

dirección X). El filtro de Prewitt "horizontal"

enfatisa bordes

"verticales" (i.e., bordes a lo largo de la dirección Y).

El campo de gradiente comprende un vector en 2D para cada píxel de la categoría de imagen de entrenamiento. Usando el análisis de componente principal, el primer componente principal del campo de gradiente se extrae sobre una máscara circular escaneada sobre la imagen. Esta es similar a

$$T = \frac{1}{n} \sum_{i=1}^n x_i x_i^T.$$

calcular los eigenvectores y eigenvalores de la matriz T . La máscara circular se obtiene a partir de una ventana cuadrada (kernel) de tamaño fijo N en donde los píxeles están dados como peso $W(x,y)$ como en la ventana Gaussiana en 2D $W(x,y)$ en donde

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

en donde $0 \leq x < N$ y $0 \leq y < N$

El análisis de componente principal genera dos atributos: (i) el vector principal de unidad $V / |V|$ (cualquiera como un valor en radianes o como componentes de x y y); y (ii) su valor principal asociado s_1 , que es también el módulo de vector principal y que resalta tendencias isotrópicas fuertes. Se debe notar que como los vectores de gradiente son ortogonales a la orientación de imagen deseada, la dirección principal debe ser rotada por 2π radianes. El campo de orientación se define por el vector principal de unidad y su valor principal asociado (o magnitud) a intervalos fijos, con valores típicos de 64 píxeles para el tamaño del kernel o máscara, y 16 píxeles para el espaciamiento de dos muestras consecutivas. El campo de orientación se puede representar ya sea por el ángulo y la magnitud de los vectores de unidad principal (en donde todos los ángulos son calculados de módulo 180 grados) o los componentes X y Y de los vectores de unidad principal de unidad y valores principales asociados.

LAS FIGS 3(A)-3(D) son una secuencia de imágenes que ilustran las operaciones de procesamiento de imagen 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 una categoría de imagen de entrenamiento ejemplar. La FIG. 3(B) es una imagen que ilustra la componente Y del campo de gradiente en 2D que es generado al aplicar el filtro de Prewitt G_y sobre la categoría de imagen de entrenamiento de la FIG. 3(A). La FIG. 3(C) es una imagen que ilustra el componente X del campo de gradiente en 2D que es generado al aplicar el filtro de Prewitt G_x sobre la categoría de imagen de entrenamiento de la FIG. 3(A). El componente principal de los vectores de orientación se puede calcular en deslizamiento trasponiendo las ventanas muestreadas regularmente (también llamada el kernel de orientación). La FIG. 3(D) es una imagen que muestra el campo de orientación, en donde el kernel de orientación es de tamaño 64x64 píxeles y es muestreado cada 16 píxeles.

Volviendo a la FIG. 4, en el bloque 411, el campo de orientación generado en el bloque 409 se usa para derivar las estadísticas que caracterizan la orientación axial de la categoría de imagen de entrenamiento y uno o más puntajes asociados con esta. Preferiblemente, tales estadísticas son parámetros de distribución que estiman la distribución de Von Mises del campo de orientación y el(los) puntaje(s) asociados(s) con esta, que caracterizan una o más de las siguientes: (i) la uniformidad/no uniformidad de la distribución de datos circular del campo de orientación, que provee una indicación que hay una o varias direcciones preferentes en la imagen, (ii) la normalidad de la distribución de datos circulares de la categoría de imagen de entrenamiento, que provee una indicación que hay una dirección dominante del campo de orientación, y (iii) la repetibilidad del campo de orientación, que provee una indicación que el campo de orientación es similar a lo largo de diferentes zonas de la imagen.

En el bloque 413, se determina si el contador "k" corresponde a la última categoría (K) de la imagen de entrenamiento. Si no, el contador "k" es aumentado en uno (i.e., $k = k+1$) en el bloque 415 y las operaciones se devuelven al bloque 405 para aislar la siguiente categoría de la imagen de entrenamiento y calcular las estadísticas de estacionariedad 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 al bloque 417

para mostrar los resultados del procesamiento de estacionariedad de orientación de los bloques 407-411 para cada categoría de la imagen de entrenamiento. Las estadísticas de estacionariedad por categoría pueden entonces ser promediadas o ponderadas de acuerdo con la significancia que el usuario quiere atribuirles para posterior procesamiento y toma de decisión.

En la realización preferida, se asume que el campo de orientación sigue una distribución normal circular. En este caso, los ángulos del módulo de 180 grados de los vectores de orientación son importantes, y las magnitudes de tales vectores son irrelevantes. Así, la distribución debe tener una simetría axial. La hipótesis de normalidad es por supuesto restrictiva pero puede ser justificada por el hecho que el campo de orientación es calculado con kernels grandes. Esto provee una hipótesis de una distribución de Von Mises 2-envuelta, que se describe en más detalles en Mardia, "Statistics of Directional Data", Academic Press, New York, 1972, 99. 57-69, incorporada aquí para referencia en su totalidad. La distribución de Von Mises es controlada por dos parámetros, el parámetro de escala κ y el parámetro de ubicación μ , y sigue la función de densidad de probabilidad (PDF)

$$f(\theta, \mu, \kappa) = \frac{1}{2\pi I_0(\kappa)} e^{\kappa \cos(2(\theta - \mu))}$$

, como se muestra en las FIGS. 5(A) y 5(B). La variable κ es la concentración (una medida inversa de la "distribución" 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 iguale a 0 cuando se vuelve uniforme. Todas las estadísticas y pruebas relacionadas con la distribución de Von Mises se pueden obtener multiplicando los ángulos por 2. La distribución de Von Mises simple sigue la

$$f(\theta, \mu, \kappa) = \frac{1}{2\pi I_0(\kappa)} e^{\kappa \cos(\theta - \mu)}.$$

función de densidad de probabilidad

Bajo el supuesto de un campo de orientación distribuido normalmente, unimodal, las siguientes formulas se usan preferiblemente para obtener un estimado $\tilde{\mu}$ de la media circular μ :

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

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

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

$$\bar{\mu} = \text{sign}(S) \times \frac{\cos^{-1}\left(\frac{\bar{R}}{C}\right)}{2}$$

Aquí C y S son los cosenos y senos de dirección, y $\bar{R}$ se define como la longitud media resultante y está directamente relacionada a la concentración κ . Estas ecuaciones se describen en detalle en Rock, "Lecture Notes in Earth Sciences 18 – Numerical Geology", Springer Verlag, 1988, incorporada aquí para referencia en su totalidad. Note que los ángulos están doblados de antemano, y así deben ser divididos por dos al final. Un estimado $\tilde{\kappa}$ se puede derivar a partir de la máxima estimación de probabilidad. Alternativamente, el estimado $\tilde{\kappa}$ se puede derivar usando la siguiente aproximación

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

La estimación de la estacionariedad de orientación de la categoría de imagen de entrenamiento requiere el 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 esta razón, se hacen pruebas de no uniformidad y normalidad en la imagen entera y en cada una de una pluralidad de zonas de superposición. En el ejemplo mostrado en las FIGS. 6(A)-6(I), la categoría de imagen de entrenamiento es dividida en 9 zonas de superposición, que son marcadas Z1, Z2, ... Z9. En esta configuración, hay $1 + 9 = 10$ pruebas diferentes. Con el fin de probar una imagen para estacionariedad de orientación, se definen tres (3) factores empíricamente: (i) la

no uniformidad del campo de orientación, que provee una indicación 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, que provee una indicación que hay una dirección dominante en el campo de orientación, y (iii) la repetibilidad del campo de orientación, que provee una indicación que el campo de orientación es similar a lo largo de las diferentes zonas de la imagen. La prueba de repetibilidad consiste en comparar las estadísticas de orientación tomadas sobre todas las parejas de zonas. Usando las 9 zonas mostradas en las FIGS. 6(A)-6(I), hay $C_9^2 = 36$ combinaciones de aquellas parejas.

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 $\bar{R}$ descrita anteriormente, con dos hipótesis a saber: (i) H_{AO} : hipótesis nula de uniformidad, i.e., el campo de orientación no tiene una dirección preferencial y podrían sacarse a partir de una distribución aleatoria; y (ii) H_{A1} : no uniformidad de la distribución de datos circulares del campo de orientación. Para valores pequeños de $N \leq 100$, la prueba es simplemente $\bar{R} > K$, y los valores críticos para $\Pr(\bar{R} \geq \bar{R}_0) = \alpha$ con los siguientes niveles de confianza $\alpha \in \{1\%, 5\%, 2.5\%, 1\%, 0.1\%\}$ son basados en tabla y preferiblemente derivados de la tabla de la página 300 de Mardia, "Statistics of Directional Data", Academic Press, New York, 1972. Para $N > 100$, la prueba se basa en $2N\bar{R}^2 > K$, en donde $2N\bar{R}^2$ está distribuida como X_2^2 . Los valores críticos para $\alpha \in \{10\%, 5\%, 2.5\%, 1\%, 0.1\%\}$ son $X_2^2 \in \{4.605, 5.991, 7.378, 9.21, 13.816\}$. Como resultado de esta prueba, el valor del nivel de confianza α que produce el valor crítico más cercano al valor probado es devuelto. El porcentaje de certeza para no uniformidad es entonces dado como $1 - \alpha$. Todas las 9 zonas y el campo de orientación completo son probados para uniformidad. El puntaje final para la no uniformidad para la imagen entera en una escala dada (o tamaño del kernel de orientación) es

$$\text{no uniformidad} = \frac{(1 - \alpha_{\text{img}}) + \sum_{i=1}^9 (1 - \alpha_{z_i})}{10}.$$

La mayor limitación de esta prueba de Rayleigh es su hipótesis de normalidad de la distribución circular que permite el cálculo de $\bar{R}$, que es la longitud media resultante sobre la cual se basa la prueba estadística. Así, si la distribución tiene, por ejemplo, dos modos obvios que están 40-60 grados separados, la prueba podría dar una alta probabilidad de no uniformidad debido a un valor relativamente alto de $\bar{R}$. En consecuencia, esta prueba no puede considerarse como una prueba que evalúa la hipótesis de uniformidad vs. Unimodalidad. Un criterio preferido es indicar el puntaje de no uniformidad de una zona dada a 0 si la prueba no puede hacerse debido a falta de normalidad de la distribución de esa zona.

La normalidad de la distribución de datos circulares del campo de orientación se estima con un valor de bondad de prueba de ajuste que determina si la suposición de una distribución de Von Mises es correcta, y confirma así una distribución normal que tiene una dirección preferencial (teóricamente unimodal de acuerdo con su PDF) o que puede volverse uniforme para un valor extremo de $\bar{R} = 0$. La prueba tiene dos hipótesis: (i) H_{B0} : hipótesis nula de bondad de valor de ajuste con la distribución de Von Mises 2-envuelta (i.e., normalidad de la distribución); y (ii) H_{B1} : no es una distribución de Von Mises (i.e., no es una distribución normal). Una prueba clásica de bondad-de-ajuste Chi-cuadrado se puede usar comparando el histograma circular $\{O_i\}_{i \in [1, 18]}$ del campo de orientación medido con el histograma teórico $\{E_i\}_{i \in [1, 18]}$ que estaría dado por una distribución de Von Mises 2-envuelta con la misma dirección media estimada $\tilde{\mu}$ y el parámetro de concentración $\tilde{\kappa}$ y calculado sobre los mismos bins $\theta_{i \in [1, 18]}$. Los datos axiales medidos están entre $[-90, 90]$ grad] y están acumulados en 18 bins $\{O_i\}_{i \in [1, 18]}$ de 10 grad de ancho que tienen los siguientes centros bin:

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

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

El criterio de prueba es $X^2 > X_{\alpha, v}^2$, en donde $X^2 = \sum_{i=1}^{18} \frac{(O_i - E_i)^2}{E_i}$. Para la prueba de Chi-cuadrado, se usa $v = 18 - 2 - 1 = 15$ grados de libertad

(comparando histogramas de 18 bins y la distribución de Von Mises tiene 2 parámetros, la ubicación y la escala). Los valores críticos para

$\alpha \in \{99.5\%, 99\%, 97.5\%, 95\%, 90\%, 75\%, 50\%, 25\%, 25\%, 10\%, 5\%, 2.5\%, 1\%, 0.5\%\}$ son

$\chi^2_{15} \in \{4.60, 5.23, 6.26, 7.26, 8.55, 11.04, 14.34, 18.25, 22.31, 25.00, 27.49, 30.58, 32.80\}$.

Como resultado de la prueba, el valor del nivel de confianza α que produce el valor crítico más cercano al valor probado es devuelto. Todas la 9 zonas y el campo de orientación entero son probados para normalidad. El puntaje final para la normalidad para la imagen entera en una escala dada (o tamaño del kernel de orientación) es:

$$normalidad = \frac{\alpha_{map} + \sum_{i=1}^9 \alpha_{z_i}}{10}.$$

La prueba de bondad-de-ajuste de Chi-cuadrado tiene limitaciones debido a la acumulación de los datos circulares en un histograma, limitaciones que se vuelven más obvias cuando el valor de concentración estimado se vuelve muy alto. En ese caso, la prueba podría dar un nivel de confianza muy bajo o nulo para las pruebas de normalidad mientras que los datos son obviamente unimodales. En consecuencia, se pueden ajustar dos condiciones que producen automáticamente un nivel de confianza $\alpha = 100\%$: e.g., (i) $\bar{x} > 20$;

y (ii) $tarjeta = \left(\{O_i\}_{i=1,14} > 0 \right) < 3$. También se provee la corrección de un artefacto numérico debido a la acumulación – que es aquella para un bin i dado, un valor pequeño de la observación estimada $0 < E_i \ll 1$ y una observación real $O_i = 1$ (siendo el número total de observaciones relativamente alto) contribuirá un gran número a las estadísticas de prueba de χ^2 , haciendo que por lo tanto, la prueba falle. Como la acumulación inadecuada contribuye en gran parte a este resultado, la contribución de esta observación real particular a la estadística de prueba de χ^2 puede ser ajustada a cero.

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 las dos muestras de la misma población (distribución); y (ii) H_{C1} = hipótesis las dos muestras no son de la misma distribución. Aquí, las dos muestras que contienen respectivamente n_1 y n_2 observaciones, en donde $N = n_1 + n_2$. Ambas muestras son combinadas y luego ordenadas. Los conjuntos $\{a_j\}_{j \in 1, N}$ y $\{b_j\}_{j \in 1, N}$ se definen a continuación. El conjunto $\{a_j\}_{j \in 1, N}$ está comprendido de los números de observaciones de la primera muestra entre las estadísticas de orden j primero de la muestra combinada. El conjunto $\{b_j\}_{j \in 1, N}$ está comprendido de los números de observaciones de la segunda muestra entre las estadísticas de orden j primero de la muestra combinada. Un valor U^2 se calcula de la siguiente forma

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

$$d_i = \frac{b_i}{n_2} - \frac{a_i}{n_1}$$

$$\bar{d} = \frac{1}{N} \sum_{i=1}^N d_i$$

Los valores críticos de $U^2_{n_1, n_2}$ para niveles de confianza de $\alpha \in \{10\%, 5\%, 1\%, 0.1\%\}$ están dados en la página 314 de Mardia, "Statistics of Directional Data", Academic Press, New York, 1972. Los detalles de esta prueba de Watson U^2 de dos muestras se describen en Mardia, "Statistics of Directional Data", Academic Press, New York, 1972, pp. 201-203, incorporada aquí para referencia en su totalidad.

La prueba de U^2 de dos muestras falla usualmente cuando la distribución de direcciones es muy angosta, probablemente porque las direcciones no están intercaladas regularmente. Como una alternativa que también es sensible a distribuciones muy angostas de ángulos $\{\theta_j\}_{j \in 1, n_1}$ y $\{\theta_j\}_{j \in 1, n_2}$, se puede usar la siguiente prueba:

$$\alpha = \begin{cases} 0 & \text{si } \left[\left[\text{rango}(\{\theta_i\}_{i \in [1, n_1]}) < 40^\circ \right] \text{ y } \left[\text{rango}(\{\theta_j\}_{j \in [1, n_2]}) < 40^\circ \right] \right] \\ & \left[\left[\min(\{\theta_i\}_{i \in [1, n_1]}) < \min(\{\theta_j\}_{j \in [1, n_2]}) \right] \text{ y } \left[\max(\{\theta_i\}_{i \in [1, n_1]}) < \min(\{\theta_j\}_{j \in [1, n_2]}) \right] \right] \\ 0 & \text{si } \left[\left[\min(\{\theta_j\}_{j \in [1, n_2]}) < \min(\{\theta_i\}_{i \in [1, n_1]}) \right] \text{ y } \left[\max(\{\theta_j\}_{j \in [1, n_2]}) < \min(\{\theta_i\}_{i \in [1, n_1]}) \right] \right] \\ 1 & \text{de otra forma} \end{cases}$$

entonces

ejecute la prueba no paramétrica U^2 de Watson

fin de la condición

Una vez la prueba es ejecutada para todos los posibles pares de zonas $C_g^2=36$, la primera parte del puntaje de repetibilidad se calcula de la siguiente forma:

$$\text{repetibilidad}_1 = \frac{\sum_{i \in [1, 9]} \sum_{j \in [1, 9]} \alpha_{2,2}}{C_g^2}$$

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 el supuesto que ambas distribuciones son Von Mises. La primera parte de esta prueba paramétrica es una prueba de concentración igual con un nivel de confianza α_k . En esta primera parte, para $\bar{R} < 0.045$, la estadística

$$Z = \frac{\frac{2}{\sqrt{3}} \left[\varphi(\bar{R}_1) - \varphi(\bar{R}_2) \right]}{\sqrt{\frac{1}{n_1 - 4} + \frac{1}{n_2 - 4}}} \quad (\text{en donde } \varphi(\bar{R}) = \sin^{-1} \left(\min \left\{ 2\bar{R} \sqrt{\frac{3}{8}}, 1 \right\} \right)),$$

se calcula y se compara con la desviación normal estándar. En lugar de buscar valores críticos en tablas, el nivel de confianza es calculado a partir de la estadística Z usando la función de distribución normal acumulativa

$$D(Z) = \frac{1 + \text{erf} \left(\frac{Z}{\sqrt{2}} \right)}{2}$$

Como la región crítica consiste de colas iguales, el nivel

de confianza es obteniendo escribiendo $\alpha_k = 1 - 2x | D(Z) - 0.5 |$. Para $0.45 \leq \bar{R} <$

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

0.7, la estadística (en donde

$$f(\bar{R}) = \ln \left[x + \sqrt{1 + x^2} \right], \quad x = \frac{\bar{R} - 1.0894}{0.2578}, \quad \text{en donde se calcula y compara con}$$

la desviación normal estándar. En lugar de buscar valores críticos en las tablas, el nivel de confianza se calcula a partir de la estadística Z usando la función de

$$D(Z) = \frac{1 + \operatorname{erf}\left(\frac{Z}{\sqrt{2}}\right)}{2}.$$

distribución normal

Como la región crítica consiste de

colas iguales, el nivel de confianza es obteniendo escribiendo $\alpha_k = 1 - 2x | D(Z) -$

$$: Z = \frac{n_1(1 - \bar{R}_1)(n_2 - 1)}{n_2(1 - \bar{R}_2)(n_1 - 1)}$$

0.5 |. Para $\bar{R} \geq 0.7$, la estadística se calcula y compara con los valores críticos de Fisher para la distribución con $n_1 - 1$ y $n_2 - 1$ grados de libertad. Los valores críticos de Fisher pueden ser observados en tablas o encontrados usando su función de distribución acumulativa siguiente:

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

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

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

Como la región constante consiste de colas iguales, el nivel de confianza puede ser obtenido escribiendo $\alpha_k = 1 - 2x | D(Z) - 0.5 |$.

La segunda parte de la prueba paramétrica para repetibilidad de la distribución del campo de orientación es una prueba de direcciones medias iguales con un nivel de confianza α_k . En esta prueba, la estadística de prueba

$$F_{1,N-2} = \frac{\left(1 + \frac{3}{8\pi}\right)(N-2)(\pi_1 \bar{R}_1 + \pi_2 \bar{R}_2 - N\bar{R})}{(N - \pi_1 \bar{R}_1 - \pi_2 \bar{R}_2)} ;$$

se calcula y compara con los valores de Fisher críticos para la distribución con 1 y $N-2$ grados de libertad. Para esta prueba particular, los valores críticos de Fisher se proveen mediante una operación de búsqueda en tabla para el siguiente nivel de confianza $\alpha \in \{10\%, 5\%, 2.5\%, 1\%\}$. Si los datos no están distribuidos normalmente (c.f., la prueba de Chi-cuadrado para normalidad), o si el nivel de confianza para la prueba de concentración igual es $\alpha_k < 0.05$, entonces el nivel de confianza para la prueba de repetibilidad se da un valor de 0. De otra forma, el nivel de confianza de la prueba de direcciones medias es entonces el nivel de confianza α_k de la prueba de repetibilidad.

La parte de concentraciones iguales o la parte de direcciones medias iguales de la segunda prueba de repetibilidad puede fallar para distribuciones muy angostas de ángulos y valores altos de las concentraciones estimadas. Esto sucede probablemente debido a que los estimados de valor de las concentraciones se vuelven menos confiables cuando las distribuciones son angostas, o la prueba se vuelve más sensible con $\bar{R}_1$ y $\bar{R}_2$ muy cerca a 1 (para la prueba de concentración y de orientación media). En consecuencia, si se desea, la segunda prueba de repetibilidad puede ser desviada cuando ambos estimados de $\bar{x}$ están por encima del umbral de 20 y la diferencia de las direcciones medias es menos de 15° . Más particularmente,

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

$$\alpha = 1$$

entonces

ejecute la segunda prueba de repetibilidad

fin de la condición

Una vez la segunda prueba de repetibilidad es ejecutada para todos los pares posibles $C^2_9 = 36$ de las zonas, el puntaje de la segunda prueba de repetibilidad se calcula de la siguiente forma

$$repetibilidad_2 = \frac{\sum_{i=1}^9 \sum_{j=1}^9 \alpha_{2,2,i}}{C^2_9}.$$

Los detalles con respecto a la primera y segunda partes de la segunda prueba de repetibilidad se indican en Mardia, "Statistics of Direccional Data", Academic Press, New York, 1972. pp. 161-162 (concentración igual) y pp. 152-155 (dirección de medias iguales), que está incorporada aquí para referencia en su totalidad.

Los puntajes de la primera y segunda partes de la segunda prueba de repetibilidad son entonces agregados para dar un puntaje total de repetibilidad (e.g., $repetibilidad = repetibilidad_1 + repetibilidad_2$).

Finalmente, las pruebas de normalidad, no uniformidad y repetibilidad en una escala dada (tamaño dado del kernel de orientación) son agrupadas. Por ejemplo, se agrupan juntas de la siguiente forma:

$$Orientación_estacionariedad = \frac{1}{4} normalidad + \frac{1}{4} no uniformidad + \frac{1}{2} repetibilidad$$

Preferiblemente, el tamaño del kernel se ajusta a $\frac{1}{2}$ de la dimensión de imagen más pequeña. Note que los puntajes de estacionariedad de orientación se expresan en porcentajes.

La FIG. 7 ilustra las operaciones del bloque 111B (FIG. 1(B)) que caracteriza la escala y estacionariedad de afinidad de la imagen de entrenamiento del bloque 109. La escala y estacionariedad de afinidad de la imagen de entrenamiento es dependiente de la rotación.

Por lo tanto, las operaciones en la imagen de entrenamiento (bloque marcado 701) empiezan por calcular el campo de orientación de la imagen de entrenamiento (bloque 703). Preferiblemente, el campo de orientación de la

imagen de entrenamiento se calcula usando la misma técnica y parámetros a los descritos anteriormente con respecto a los bloques 407 a 409 de la FIG. 4. Este campo de orientación se calcula para todas las categorías de la imagen de entrenamiento. Los atributos de textura usados para el cálculo de la escala y estadísticas de afinidad son características extraídas de las Matrices de Co-Ocurrencia de Nivel de Gris (explicado más adelante con respecto a los bloques 709 y 719). Esta metodología requiere medir la diferencia en intensidad de nivel de gris entre pares vecinos de píxeles a desplazamientos dados. Cada píxel de la imagen se compara con los píxeles de la misma imagen pero tomados en un número de desplazamientos diferentes (en la realización preferida, 28 desplazamientos diferentes). Para un desplazamiento particular, los píxeles desplazados son agrupados en una imagen de desplazamiento. Por lo tanto, en la realización preferida, tenemos 28 imágenes de desplazamiento. En los bloques 705 y 707, la imagen de entrenamiento es muestreada usando 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 descrita más adelante, la información de orientación está integrada en las imágenes de desplazamiento utilizando muestreo dependiente de la rotación. Estas imágenes de desplazamiento se usan para calcular las Matrices de Co-Ocurrencia de Nivel de Grises de pequeñas ventanas deslizantes escaneadas sobre la imagen (bloque 709). Los vectores de característica de textura se derivan a partir de estas Matrices de Co-Ocurrencia de Nivel de Grises (bloque 711).

En una ruta paralela, una región (o zona) de la imagen de entrenamiento es seleccionada (bloque 713). Esta región o zona, que es referida más adelante como un patrón de referencia, tiene las mismas dimensiones que las ventanas deslizantes usadas en el bloque 709. Similares a las operaciones de los bloques 705 – 711, el patrón de referencia es muestreado usando el campo de orientación como una guía (bloque 715). Sin embargo, al muestrear la imagen pequeña del patrón de referencia, no solamente la imagen es corregida para orientación sino que las diferentes transformaciones de afinidad son impuestas en el sistema de vecindad circular usado para el muestreo. Modificando los factores de afinidad se obtienen diferentes escalas y elongaciones a lo largo de los ejes X y Y, derivando así imágenes de desplazamiento a diferentes afinidades (bloque 717). Así, en la realización preferida, en lugar de tener solo 28 imágenes de desplazamiento y 1 vector de atributos de textura (como en 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 de textura para el patrón de referencia, en donde N es un número de parejas de afinidad (X, Y) . Para cada elección de la afinidad X y Y , se realiza un muestreo dependiente de la rotación del patrón de referencia. En la realización ilustrativa mostrada en la FIG. 10, N se selecciona para ser igual a 25 con 5 valores posibles para la afinidad a lo largo del eje X (e.g., $x0.5$, $x0.667$, $x1$, $x1.5$, $x2$) y 5 valores posibles para la afinidad a lo largo del eje Y (e.g., $x0.5$, $x0.667$, $x1$, $x1.5$, $x2$). Las imágenes de desplazamiento generadas en el bloque 719 se usan para calcular las Matrices de Co-Ocurrencia de Nivel de Gris de pequeñas ventanas deslizantes escaneadas sobre la imagen (bloque 719). Los vectores de característica de textura se derivan de estas Matrices de Co-Ocurrencia de Nivel de Gris (bloque 721). Los vectores de característica de textura generados en el bloque 721 se derivan de diferentes transformaciones de escala (que algunas veces son referidos aquí como "dilataciones de afinidad") del mismo patrón de referencia. En el bloque 723, las operaciones miden la similitud (e.g., una distancia Euclidiana) entre los vectores de característica de textura generados en el bloque 721 y los vectores de característica de textura generados en el bloque 711. En el bloque 725, para una zona dada (ventana deslizante) de la imagen de entrenamiento, las operaciones seleccionan la transformada 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 ser interpretados como un mapa de afinidad de la imagen de entrenamiento bajo el supuesto que un único patrón de referencia es reproducido sobre la imagen entera en diferentes escalas.

En el bloque 727, las estadísticas de estacionariedad y un puntaje son calculados usando las transformadas de afinidad identificadas en el bloque 725. En el bloque 729 se pueden mostrar los mapas de afinidad (también referidos aquí como mapas de similitud). Las estadísticas y puntaje calculados en el bloque 727 y el mapa de afinidad mostrado en el bloque 729 se relacionan con un patrón de referencia particular seleccionado en el bloque 713.

En el bloque 731 se determina si las operaciones deben revertirse al bloque 713. Esta decisión se puede tomar de acuerdo con la entrada del usuario o automáticamente por una ventana deslizante. Si la decisión en el bloque 731 es si, otro patrón de referencia es seleccionado en el bloque 713 y las estadísticas de estacionariedad y puntaje relacionado a estas son

generados en los bloques 715-729 como se describió anteriormente. Si la decisión en el bloque 731 es no, se puede calcular un promedio de los puntajes generados en el bloque 727 sobre un número de patrones de referencia en el bloque 733, y/o 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 en el bloque 735, y el proceso termina.

En la realización preferida, la derivación de las imágenes de desplazamiento de los bloques 705/707 y bloques 715/717 emplean la principal del sistema circular de orden N^a , que se explica en detalle en Deng et al., "Gaussian MRF Rotation – Invariant Features for Image Classification". IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 26. No. 7, Julio 2004. Más particularmente, este sistema de vecindad circular isotrópica se usa para el muestreo de pixels vecinos relativos a un pixel central de referencia. Los vecinos muestreados están todos situados en círculos concéntricos de radio de píxel $r=1, r=2, r=3, \dots r=N$, en donde N es el orden de la vecindad. Se puede usar una interpolación bilineal para interpolar los valores de intensidad de las muestras que no caen exactamente en el centro de los pixeles. La FIG. 8 muestra el sistema de vecindad de 4^a orden circular en la realización preferida, con respectivamente 4, 6, 8 y 10 muestras tomadas en los semi-círculos de radios $r_1=1, r_2=2, r_3=3$ y $r_4=4$. Estas muestras se suman para dar $4 + 6 + 8 + 10 = 28$ puntos de desplazamiento de la siguiente forma:

$$\begin{aligned} \forall k \in [1, 4], \begin{cases} \theta_k = \frac{(k-1)\pi}{4} \\ u_k = r_1 \cos(\theta_k) \\ v_k = r_1 \sin(\theta_k) \end{cases} & \quad \forall k \in [5, 10], \begin{cases} \theta_k = \frac{(k-5)\pi}{6} \\ u_k = r_2 \cos(\theta_k) \\ v_k = r_2 \sin(\theta_k) \end{cases} \\ \forall k \in [11, 18], \begin{cases} \theta_k = \frac{(k-11)\pi}{8} \\ u_k = r_3 \cos(\theta_k) \\ v_k = r_3 \sin(\theta_k) \end{cases} & \quad \forall k \in [19, 28], \begin{cases} \theta_k = \frac{(k-19)\pi}{10} \\ u_k = r_4 \cos(\theta_k) \\ v_k = r_4 \sin(\theta_k) \end{cases} \end{aligned}$$

Tal muestreo tiene la ventaja de proveer un cubrimiento completo de cada píxel en la vecindad circular sin caer en la trampa de muestrear varias veces el mismo pixel o pixeles par.

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

$$\begin{bmatrix} u' \\ v' \end{bmatrix} = \begin{bmatrix} \cos(\phi) & \sin(\phi) \\ -\sin(\phi) & \cos(\phi) \end{bmatrix} \begin{bmatrix} u \\ v \end{bmatrix}$$

Una realización ejemplar de tal muestreo dependiente de la rotación usando un sistema de muestreo de vecindad circular se ilustra en la FIG. 9, con una rotación $\phi = -60$ grados. La realización de la FIG. 9 también agrega el muestreo dependiente de la escala descrito más adelante, que puede ser ignorado para los propósitos de los bloques 705 y 707. Como el muestreo de vecindad no-rotado, se puede usar una interpolación bilineal para interpolar los valores de intensidad de las muestras que no caen exactamente en el centro de los píxeles. Como la representación de imagen de la pantalla usa el sistema de coordenadas Cartesianas indirectas, en donde el eje Y está invertido y orientado "descendentemente" mientras que el eje X está aún orientado "hacia la derecha", se aplica una rotación por un ángulo de $-\phi$ a las coordenadas de muestreo de vecindad circular. Los parámetros de rotación del sistema de muestreo de vecindad descrito anteriormente se derivan de los vectores del campo de orientación calculados en el bloque 703. Más particularmente, para cada píxel de la imagen de entrenamiento o cada píxel del patrón de referencia, hay un valor de la dirección ϕ del vector de orientación, produciendo el parámetro ϕ de la rotación del sistema de muestreo de vecindad. En la realización preferida, el muestreo de vecindad circular rotado produce 28 píxeles desplazados para cada píxel de la imagen de entrenamiento. De esta forma, el muestreo dependiente de la rotación produce 28 imágenes de desplazamiento de la imagen de entrenamiento para posterior análisis en el bloque 711.

Para las operaciones de los bloques 715 y 717 que generan las imágenes de desplazamiento para un patrón de referencia particular, el sistema de vecindad circular está adaptado para muestreo dependiente de la rotación y de la escala. Más particularmente, se usa una transformada de afinidad del sistema de muestreo de vecindad de orden n^o con el fin de capturar las características de textura en una escala X y Y local dada y en una orientación local dada. Este criterio es el inverso de la generación estocástica de imágenes a través de geoestadísticas de multipunto. De hecho, como se explica en Caers, "Geostatistical history matching Under training-image based geological model constraints", SPE Journal, No. 74716, 2003, pp. 218-226, la información de escala local (afinidad) y orientación se puede usar para controlar la realización de un proceso estocástico y permite la repetición de un patrón a escalas y orientaciones diferentes. Los factores de afinidad a_x y a_y describen la transformación de escala (dilatación) del patrón de referencia a lo largo del eje X y el eje Y respectivamente. En la realización ilustrativa mostrada en la FIG. 10, hay 5 valores posibles para el factor de afinidad a_x (e.g., $x0.5$, $x0.667$, $x1$, $x1.5$, $x2$) y 5 valores posibles para el factor de afinidad a_y (e.g., $x0.5$, $x0.667$, $x1$, $x1.5$, $x2$), proporcionando así un total de 25 pares (o parejas) diferentes de factor de afinidad. Cuando la relación de aspecto a_y/a_x no es 1, entonces ese patrón está alargado ya sea a lo largo del eje X o el eje Y . La afinidad total y transformación de rotación de las coordenadas del muestreo de vecindad circular se pueden escribir de la siguiente forma:

$$\begin{bmatrix} u^{tr} \\ v^{tr} \end{bmatrix} = \begin{bmatrix} \cos(\phi) & \sin(\phi) \\ -\sin(\phi) & \cos(\phi) \end{bmatrix} \begin{bmatrix} a_x & 0 \\ 0 & a_y \end{bmatrix} \begin{bmatrix} u^r \\ v^r \end{bmatrix}.$$

Una ilustración de un sistema de muestreo de vecindad circular de 4^o orden rotada y escalada está dada en la Figura 9 con una rotación $\phi = -60$ grados y la pareja de factor de afinidad $(a_x, a_y) = (0.5, 1)$. El factor de afinidad a_x 0 0.5 indica que el muestreo de vecindad se "acerca" a lo largo del eje X cuando se muestrea el patrón. Es equivalente 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 vecindad descritos anteriormente se derivan de los vectores del campo de orientación calculados en el bloque 703. Más particularmente, para cada píxel de la imagen de entrenamiento o cada píxel del patrón de referencia, hay un valor de la dirección ϕ del vector de orientación, produciendo el parámetro ϕ de la rotación del sistema de muestreo de vecindad. Los

parámetros de afinidad (a_x, a_y) son constantes en toda la imagen. Sin embargo, para cada conjunto de aquellos parámetros de afinidad, se calcula un nuevo conjunto de imágenes de desplazamiento para análisis posterior en el bloque 721. En la realización preferida, el muestreo de vecindad circular dependiente de la rotación y la escala produce 25 conjuntos de 28 píxeles desplazados para cada píxel del patrón de referencia, uno conjunto para cada combinación de factores de afinidad de X y Y . De esta manera, el muestreo dependiente de la rotación y la escala produce 25 conjuntos de 28 imágenes de desplazamiento del patrón de referencia para análisis posterior en el bloque 721.

Como se describió anteriormente, las operaciones de los bloques 709 y 711 derivan características de textura (referida más adelante como "atributos de textura" o "elementos") a partir de matrices de co-ocurrencia del nivel de gris calculados en las imágenes de desplazamiento de la imagen de entrenamiento. En la realización preferida, las matrices de co-ocurrencia del nivel de grises se calculan de la siguiente forma. Primero, la imagen de entrenamiento y las imágenes de desplazamiento son cuantificadas en niveles de grises G (por ejemplo $G = 32$). Note que incluso al realizar un análisis de multi-resolución de patrones de blanco y negro, se usan más de 2 niveles de grises porque durante el muestreo de vecindad circular con transformaciones de escala y orientación, la mayoría de las muestras no caen en los centros de los píxeles y son interpolados. Adicionalmente, si hay más de 2 pero menos de G categorías en la imagen de entrenamiento, tal cuantificación del nivel de grises permite que las operaciones mantengan una distinción entre cada categoría. Las imágenes cuantificadas son luego procesadas para calcular un conjunto de matrices de co-ocurrencia. Cada matriz de co-ocurrencia, que puede ser denotada $C_d(k, l)$, estima la probabilidad que ocurran los niveles de grises k y l en la imagen cuantificada $I(x, y)$ en un desplazamiento de d . Esta probabilidad se mide contando el número de pares (x, y) y (x', y') en donde $I(x, y) = k$, $I(x', y') = l$ y $(x' - x, y' - y) = d$, y luego dividiendo ese número de pares por el número total de píxeles vecinos en la imagen. El conjunto 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 formula:

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

Como se muestra en la FIG. 11, cada matriz de co-ocurrencia no es calculada sobre la imagen de entrenamiento entera, sino en pequeñas ventanas deslizantes extraídas de la imagen y muestreadas regularmente. La FIG. 11 ilustra la generación de matrices de co-ocurrencia (y vectores de característica de textura derivados de estas). En la FIG. 11, las tres regiones a, b y c ilustran las ubicaciones posibles de la ventana deslizante. En la realización preferida, las ubicaciones de la ventana deslizante están regularmente muestreadas sobre la imagen en entrenamiento entera. Para 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 posteriores y las estadísticas que matriz de co-ocurrencia que se calculan. Note que si el tamaño de la ventana deslizante aumenta, se capturan más características de textura; sin embargo la resolución de los mapas de afinidad derivados de esta en el bloque 725 disminuye.

Después de haber calculado el conjunto de matrices de co-ocurrencia, se calculan seis características de textura a partir de cada matriz de co-ocurrencia usando las siguientes formulas, (en donde $p(k, l)$ es un elemento de una matriz de co-ocurrencia dada):

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

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

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

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

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

vi) probabilidad máxima:
$$\max_{k,l} p(k,l);$$

Detalles más específicos con respecto a estas descripciones se pueden encontrar en Haralick et al, "TextureFeatures for Image Classification", IEEE Transactions on systems Man and Cybernetics, SMC-3, No. 6, 1973, pp. 610-621, y Materka et al., "Texture Analysis Methods – A Review", Technical University of Lodz, Institute of Electronics, COST B11 report, Brussels, 1998, incorporadas aquí para referencia en su totalidad. De esta forma, un vector de 6 elementos caracteriza cada matriz de co-ocurrencia, que reduce la dimensionalidad de las medidas de textura. En la realización preferida, las 6 características de textura para cada una de las 28 matrices de co-ocurrencia se agrupan juntas para generar un vector de 168 elementos que están asociados con la imagen de entrenamiento.

En la realización preferida, se realizan operaciones similares a las descritas antes con respecto a los bloques 709 y 711 para derivar características de textura a partir de matrices de co-ocurrencia de nivel de grises calculadas en las imágenes de desplazamiento del patrón de referencia en los bloques 719 y 721. En tales operaciones se calcula un conjunto de matrices de co-ocurrencia (preferiblemente 28) para cada pareja de factor de afinidad designada (e.g., para cada una de las 25 parejas de factor de afinidad). Cada matriz de co-ocurrencia se calcula sobre el patrón de referencia entero. Las 6 características de textura son entonces generadas para cada matriz de co-ocurrencia. En la realización preferida se generan 25 vectores de características de textura (cada vector contiene 168 elementos). Los 25 vectores corresponden a las 25 parejas de factor de afinidad descritas anteriormente con respecto a la FIG. 10.

Como se describió anteriormente, las operaciones de bloque 723 miden la similitud (e.g., una distancia Euclidiana) entre los vectores de característica de textura generados en el bloque 721 y los vectores de característica de textura generados en el bloque 711. En la realización preferida, esto se realiza

generando, para cada región r de la imagen de entrenamiento, la dilatación a (más de 25 dilataciones posibles af) del patrón de referencia que minimiza la distancia euclidiana entre los vectores de característica de textura $V_{T,r}$ y $V_{RP,af}$, que está representada matemáticamente de la siguiente forma:

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

La dilatación $a(r)$ se calcula para cada región r como se indica mediante las flechas de línea delgada que unen los pares de vector de característica en la FIG. 11. La FIG. 11 ilustra la comparación entre los vectores de característica de textura para tres regiones diferentes a , b , c de la imagen de entrenamiento y diferentes transformaciones de afinidad del patrón de referencia, denotadas (x_1, y_1) , (x_2, y_2) , $(x_3, y_3) \dots (x_N, y_N)$.

La distancia euclidiana mínima entre los vectores de característica produce un mapa de afinidad que muestra los mejores factores de afinidad para las regiones de la imagen de entrenamiento. La FIG. 11 ilustra un mapa de afinidad ejemplar que muestra los mejores parámetros de afinidad (x_a, y_a) , (x_b, y_b) , (x_c, y_c) para las regiones a , b , c , respectivamente. Este mapa de afinidad se puede mostrar en el bloque 729 como se describió anteriormente.

Las FIGS. 12(B) y 12(C) ilustran otra forma de mapa de afinidad en donde se proveen imágenes en 2D separadas para las parejas de factor de afinidad. Cada imagen en 2D describe la distancia entre los vectores de característica para partes correspondientes 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 en 2D 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 en 2D son binarios con las distancias representadas por los píxeles asignados a un rango de valores binarios. Las distancias más cercanas a un valor binario (i.e, negro), mientras las otras distancias son asignadas al otro valor binario (i.e, 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 diferentes transformaciones de afinidad en el resto de la imagen: en la esquina superior izquierda, el patrón tiene una transformación de afinidad (a_x

= 1, $a_y = 1$); en la esquina superior derecha, el patrón es reproducido dos veces en una transformación de afinidad ($a_x = 1$, $a_y = 0.5$); en la parte media izquierda de la imagen, el patrón es reproducido dos veces en una transformación de afinidad ($a_x = 0.5$, $a_y = 1$); en la parte media derecha de la imagen, el patrón es reproducido 4 veces en una transformación de imagen ($a_x = 0.5$, $a_y = 0.5$); en la parte inferior de la imagen, el patrón tiene una transformación de afinidad ($a_x = 2$, $a_y = 1$). La imagen entera 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) se selecciona 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 característica de textura extraídos de la imagen de entrenamiento y los vectores de característica de textura del patrón de referencia para 9 parejas de factor de afinidad diferentes. El mapa de afinidad de la FIG. 12(C) muestra la distancia binaria (i.e., las distancias más cercanas en negro) entre vectores de característica de textura extraídos de la imagen de entrenamiento y los vectores de característica de textura del patrón de referencia para 9 parejas de factor de afinidad diferentes. La correlación entre la afinidad visible de la imagen de entrenamiento y los resultados son muy buenos en la medida en 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 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 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 en la imagen de entrenamiento: como se espera, en la esquina superior izquierda de la imagen de entrenamiento que también se usó como el patrón de referencia, y hacia la parte inferior de la imagen de entrenamiento. Este artefacto en afinidad ($a_x = 1$, $a_y = 1$) se debe a la discontinuidad de borde en la imagen en 2D que es interpretada como un cambio de escala.

En la realización preferida, las operaciones del bloque 727 utilizan los principios de los mapas de afinidad descritas anteriormente para generar estadísticas de estacionariedad de escala. La estacionariedad de escala, con relación a un patrón de referencia, se puede medir por cuántas escalas diferentes (y relaciones de aspecto) son cubiertas por esa imagen, o cómo la imagen se distribuye en una escala-espacio cuando se asume que la imagen se deriva de una repetición de un patrón único en diferentes escalas y

orientaciones. Más particularmente, la estacionariedad de escala se puede definir como la partida de un valor simple agrupado de (Xx_1, Yx_1) en el mapa de afinidad; entonces cualquier variación a lo largo de los ejes X o Y del mapa de afinidad indica una imagen de no estacionariedad. En la realización preferida, la estacionariedad de escala de la imagen se mide calculando la distribución de la nube de puntos $p_1, p_2, \dots p_n$ definidos por las mejores coincidencias entre la imagen y los patrones dilatados. La medida de distribución puede entonces ser calculada simplemente como una medida de distribución de puntos en un espacio de dos dimensiones como se muestra en la FIG: 13. Estos puntos de mejor coincidencia se ubican in una escala-espacio en donde el eje X corresponde a la dilatación posible 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 soma pequeña diferente en la imagen, describe por su ubicación en ese espacio-escala, los factores de dilatación x y y. La escala-espacio no es continua sino discreta, porque solo se calcula un pequeño número de dilataciones del patrón de referencia. Los factores de dilatación son mapeados en la escala-espacio a través de una bisección (i.e., un mapeo uno-a-uno). En la realización preferida, los factores de dilatación x son $\frac{1}{2}, \frac{2}{3}, 1, \frac{3}{2}$ y 2 y corresponden a las abscisas de -1, -1/2, 0, $\frac{1}{2}$ y 1. Tal escala espacio se representan en la FIG. 13. En este ejemplo, la representación escala-espacio de la distribución de una nube de puntos se simboliza mediante una elipse. Se muestran las direcciones de componente principal primero y segundo. Los dos componentes principales de los puntos $p_1, p_2, \dots p_n$ se obtienen mediante la

$$(SVD) \begin{bmatrix} x_i \\ y_i \end{bmatrix}_{i=1}^n = U \times S \times V^T$$

descomposición del valor singular . 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 (que se pueden recuperar de la diagonal de la matriz S) proporciona la importancia de la variación de los puntos $p_1, p_2, \dots p_n$ a lo largo de la dirección de la segunda dirección principal. Deje que $u = (u_x, u_y)$ sea el vector unitario que define la dirección del primer componente principal y deje que $v = (v_x, v_y)$ sea el vector unitario que define la dirección del segundo componente principal (u y v son ortogonales). Los vectores unitarios u y v se pueden obtener normalizando la primera y segunda columna de la matriz V. Las coordenadas de $p_1, p_2, \dots p_n$ en el sistema de coordenadas u, v se puede

obtener a partir de $\begin{bmatrix} u_i \\ v_i \end{bmatrix}_{i=1, \dots, n} = U \times \begin{bmatrix} x_i \\ y_i \end{bmatrix}_{i=1, \dots, n}$. La "distribución" de la nube de puntos se define dependiendo 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 dirección principal se calcula de la siguiente forma:

$$\text{stdev}(u_i)_{i=1, \dots, n} = \sqrt{\frac{1}{n-1} \sum_{j=1}^n (u_j - \bar{u})^2}, \quad \bar{u} = \frac{1}{n} \sum_{i=1}^n u_i.$$

en donde

La distribución total de la nube de puntos $p_1, p_2, \dots, p_n$ se define de la siguiente forma

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

Esta formula ha sido concebida con el fin de dar una distribución más fuerte cuando la nube de puntos tiene una forma elíptica o circular que cuando la distribución es solamente con una relación Y/X constante. Más aún, también se restringe entre los valores de 0 (todos los puntos están concentrados en el punto medio (0, 0), i.e., todas las escalas son x1, x1) y 1. El puntaje de estacionariedad de escala es simplemente 1- distribución (i.e., $\text{escala_estacionariedad} = 1 - \text{distribución}$) y se expresa como un porcentaje. En la realización preferida, se emplea un cálculo de puntaje de estacionariedad de escala automatizado en el bloque 727 que calcula el valor mínimo de 9 puntajes de estacionariedad de escala calculado con referencia a los patrones localizados en la parte superior derecha, superior media, superior izquierda, derecha media, central, izquierda media, derecha de fondo, media de fondo e izquierda de fondo del entrenamiento, que es similar al cálculo del puntaje de estacionariedad de orientación como de describió anteriormente. Estas operaciones se pueden representar matemáticamente como

$$\text{escala_estacionariedad} = \min_{k=1}^9 (\text{escala_estacionariedad}_k).$$

Las operaciones del bloque 111C (FIG. 1(B)) que caracteriza la estacionariedad de distribución de categoría de la imagen de entrenamiento del bloque 109 verifica que la distribución de categorías no cambia considerablemente de una región de la imagen a otra. En la realización

preferida, la imagen de entrenamiento es sub-dividida en zonas de forma similar a la descrita anteriormente con respecto a las FIGS. 6(A) – 6(I) para generar las estadísticas de estacionariedad de orientación. Un histograma de distribución de categoría H_k se calcula en cada zona k fuera de las 9 zonas de la realización preferida. Los histogramas de distribución de categoría contienen todos G bins, en donde G es el número de categorías. La similitud de dos histogramas de escala de grises H_k y H_l se mide usando la distancia euclidiana entre los vectores H_k y H_l :

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

El puntaje de estacionariedad de distribución de categoría para todas las zonas se calcula de la siguiente forma:

$$clase\ de\ color_estacionariedad = 1 - \min \left(1, \max_{i,j} \left(\sqrt{\sum_{c=1}^G [H_i(c) - H_j(c)]^2} \right) \right).$$

En el bloque 113, los puntajes de estacionariedad generados en el bloque 111 se analizan para determinar si la imagen de entrenamiento satisface un conjunto de restricciones predeterminadas que dictan si la imagen de entrenamiento debe o no ser usada en el análisis geoestadístico de multipunto posterior. En la realización preferida, el puntaje de estacionariedad de orientación (111A) el puntaje de estacionariedad de escala (bloque 111B), y el puntaje de estacionariedad de distribución de categoría (bloque 111C) son graficados en una gráfica tridimensional cuyos ejes corresponden a los tres puntajes como se ilustra en la FIG. 14. Se define un conjunto de superficies que representa una o más regiones en el espacio tri-dimensional que delimita "buenas" imágenes de entrenamiento. Si los tres puntajes para la imagen de entrenamiento particular caen dentro de una o más regiones que delimitan "buenas" imágenes de entrenamiento, el criterio de estacionariedad del bloque 113 es satisfecho; de otra forma, el criterio de estacionariedad del bloque 113 falla.

En el caso que el criterio de estacionariedad del bloque 113 es satisfecho, la imagen de entrenamiento puede ser exportada como una

cuadrícula de imagen para análisis geoestadístico de multipunto (bloque 119). Ejemplos de tal análisis geoestadístico de multipunto incluyen una implementación basada en computadora del algoritmo SNESIM y/o una implementación basada en computadora del algoritmo SIMPAT.

En el método SNESIM (Simulador de Ecuación normal Simple), la función de densidad de probabilidad condicional de todas las categorías en un punto se calcula usando el conocimiento del valor en un pequeño número de puntos cercanos y las estadísticas proporcionadas por una "imagen de entrenamiento". El SNESIM trabaja solamente con valores discretos (i.e., un número finito y usualmente pequeño de categorías, tales como por ejemplo cinco tipos de rocas diferentes). Asume que hay dos categorías a ser simuladas: A (intra-canal) y B (canal). La imagen de entrenamiento contiene una representación completa (i.e., un ejemplo) de una distribución espacial de A y B. 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 categorías A y B en un quinto punto (u_5) consultando la imagen de entrenamiento para todas las ocurrencias del "patrón" (u_1, u_2, u_3, u_4) (que es la ocurrencia de 4 puntos con las mismas ubicaciones relativas entre sí y los mismos valores de categoría en la imagen de entrenamiento) como se muestra en la FIG. 15. Si se encuentran tales 5 ocurrencias (estas son llamadas réplicas), y 4 de 5 réplicas muestran categorías B en la posición relativa del punto desconocido (u_5), entonces el método concluye que la probabilidad de B en el punto desconocido es del 80% (mientras que el de A es 20%). Adicionalmente, el método puede asignar una categoría al punto desconocido dibujando aleatoriamente un valor de una distribución con 80% de probabilidad de B y 20% de probabilidad de A. En la práctica, el método SNESIM parte con un volumen blanco a ser modelado, o uno que contiene solamente unos pocos datos a ser replicados, y primero decide una ruta aleatoria para visitar cada uno de los píxeles blancos una y solamente una vez. En el primer píxel, el método requiere la búsqueda de puntos cercanos conocidos dentro de una elipsoide de búsqueda. Si se encuentran uno o más píxeles conocidos (o ya asignados), se procede como se describió anteriormente para encontrar la probabilidad de encontrar las categorías A o B en el punto desconocido. Armado con las probabilidades para cada categoría en el punto desconocido, el método dibuja aleatoriamente un valor (ponderado mediante las probabilidades conocidas) y lo asigna al punto

desconocido. El proceso se repite en el siguiente píxel en la ruta aleatoria asignada inicialmente hasta que todos los píxeles son asignados.

Tal metodología era bien conocida a principios de los 90 (antes que fuera conocida como "SNESIM"). Uno de sus problemas, sin embargo, fue que era extremadamente computacionalmente intensivo consultar la imagen de entrenamiento veces múltiples. En el 2000, se descubrió una técnica para almacenar la información contenida en la imagen de entrenamiento en una estructura tipo tres especial que redujo los cálculos enormemente. Con esta mejora, la metodología fue referida comúnmente como el método "SNESIM". Acoplado con el poder establemente en aumento de las computadoras digitales, el problema de consulta de imagen se trajo a tiempos de procesamiento razonables (aunque aún significativos).

La metodología de SNESIM de núcleo tiene varias variaciones y adiciones que lo usan para hacerlo más poderoso y útil. Un mejoramiento agrega la habilidad de procesar en etapas sucesivas de resolución en aumento, que mejoran la continuidad lateral de las características. El número de refinamientos se llama multiplicidad. Otro mejoramiento provee la habilidad de usar probabilidades blandas (posiblemente derivadas de datos sísmicos) para controlar más el modelamiento. A través de más adiciones, el método de SNESIM puede manejar transformaciones de escala simplemente escalando las distancias a los puntos conocidos (u_1, u_2, u_3, u_4) en el ejemplo anterior) de acuerdo con la información de escalamiento dependiente de ubicación proporcionada por el usuario. Igualmente, puede incorporar información sobre la rotación de características geológicas (tales como direcciones de canal) rotando el conjunto de puntos de acuerdo con el valor local de un campo de rotación proporcionado por el usuario.

En el método SIMPAT (Simulación con patrones), se calcula la probabilidad de ocurrencia de todas las combinaciones de valores dentro de un pequeño conjunto de puntos contiguos (tales como una matriz rectangular). A diferencia del método de SNESIM, el método SIMPAT puede trabajar con valores discretos (categoría) o valores numéricos continuos. Más particularmente, el método SIMPAT estima tales probabilidades en la imagen de entrenamiento contando las ocurrencias de estos patrones mediante una plantilla rectangular en movimiento que escanea la imagen entera. Por ejemplo, si se aplica a una imagen en 2 dimensiones binaria con una plantilla de 2x2

pixeles, el método asigna una probabilidad de ocurrencia de cada posible resultado de la plantilla de 2x2 pixeles (a saber 24 o 16 resultados posibles). El resultado es una distribución de probabilidad cuyo dominio consiste de 24 combinaciones de píxel como se muestra en la FIG. 16(A). En la práctica, las plantillas más grandes (de hasta aproximadamente 8x8 pixeles) se usan para conducir un número muy grande de combinaciones posibles, aunque muchas pueden tener una ocurrencia o probabilidad de cero, si están ausentes en la imagen de entrenamiento. La simulación se logra dibujando aleatoriamente desde la distribución para llenar progresivamente una imagen inicialmente vacía. Se debe tener cuidado de replicar pixeles ya llenos, o pixeles que representan datos de acondicionamiento duros. Esto se puede lograr dibujando un subconjunto de la distribución original de los grupos de píxel, a saber subconjuntos de aquellos grupos de píxel que honor los datos pre-existentes.

La necesidad de coincidir puntos pre-existentes puede conducir a tiempos de cálculo extensos con patrones más grandes, porque muchos puntos necesitan ser coincidos simultáneamente a lo largo de los bordes de patrones más grandes. Esto ha conducido a uso de una método de alguna forma más refinado llamado geoestadísticas "basadas en características", que se basa en una plantilla que contiene una "característica" interior y una "capa" exterior como se muestra en la FIG. 16(B). En la práctica, la característica es generalmente más grande de 2x2 pixeles, pero la piel es típicamente de un píxel de ancho. Esta partición facilita la clasificación de la plantilla. Al escanear la imagen, el método obtiene una recolección de características y sus probabilidades de ocurrencia. Una característica dada (2x2 pixeles en este ejemplo) puede ocurrir varias veces, pero cada vez con una capa diferente. Por lo tanto, cada característica tiene una probabilidad, pero muchas capas posibles, cada una de las cuales a su vez tiene su probabilidad (relativa a la característica). Cuando una característica necesita ser asignada siguiente a una existente, se saca de todas las características con una capa de coincidencia, ponderada por la probabilidad de cada posible capa en la característica existente. Así, la capa restringe la probabilidad de ocurrencia de la característica en su vecindad inmediata, y permite la coincidencia de las características de vecindad.

El método SIMPAT se puede extender en formas que son de alguna forma, similares a las extensiones del método SNESIM. A saber, realizar la

simulación en etapas que varían desde una cuadrícula gruesa (por ejemplo una cuadrícula que solamente usa cada quinto píxel en cada dirección) a una cuadrícula más fina, y usando los resultados cada etapa previa (más gruesa) como valores a ser replicados en la siguiente etapa (más fina), el método SIMPAT mejora en gran medida su habilidad para replicar la continuidad de características largas (tales como canales). Además, los patrones pueden ser escalados y rotados para replicar información de escalamiento y rotación local proporcionada por el usuario. En general, el método SIMPAT logra mejores resultados que el método SNESIM (en que replica las estadísticas de la imagen de entrenamiento original más cercanamente), pero también es computacionalmente más lento.

En el evento en que el criterio de estacionariedad del bloque 113 falle, la imagen de entrenamiento de no estacionariedad puede ser exportada como una cuadrícula de imagen para análisis geoestadístico de multipunto (bloque 127A). Igualmente, la cuadrícula de orientación y los mapas de afinidad derivados como parte del cálculo de las estadísticas de estacionariedad de aquí pueden ser exportados como cuadrículas de restricción para análisis estadísticos de multipunto que aceptan imágenes de entrenamiento no estacionarias.

La metodología basada en computadora descrita anteriormente puede extenderse fácilmente a las imágenes de entrenamiento tridimensionales. Más particularmente, el flujo de trabajo de la FIG. 1B sería modificado de la siguiente manera. Primero, los bloques 101-105 están adaptados para almacenar y recuperar imágenes en 3D. Segundo, el bloque 107 está adaptado para usar versiones en 3D de las operaciones de procesamiento de imagen en 2D descritas anteriormente con el fin de pre-procesar imágenes en 3D y crear imágenes de entrenamiento en 3D válidas. Finalmente, el bloque 111 está adaptado para usar estadísticas. Más particularmente, en lugar de subdividir la imagen de entrenamiento en 9 rectángulos de superposición (FIGS. 6(A)-6(I)). La imagen de entrenamiento en 3D puede ser subdivida en 27 cubos de superposición. Se usa una versión en 3D 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 en 3D son perpendiculares a las superficies de gradiente.

Estos vectores de orientación en 3D son datos esféricos sobre los cuales las estadísticas de estacionariedad son extraídos. Las versiones en 3D de las

operaciones descritas anteriormente para evaluar la estacionariedad del campo de orientación se describen en Mardia, "Statistics of Directional Data", Academic Press, New York, 1972, y Rock, "Lecture Notes in Earth Sciences 18 – Numerical Geology", Springer Verlag, 1988, incorporadas aquí para referencia en su totalidad. También se usarían las versiones en 3D de las operaciones descritas anteriormente para acceder a la estacionariedad de escala. En tales operaciones, las matrices de co-ocurrencia de nivel de grises usadas allí requieren un sistema de vecindad esférico en lugar de uno circular. Las estadísticas de estacionariedad de escala en sí se harían en mapas de afinidad escala-espacio en 3D usando la versión en 3D de la SVD y desviación estándar. Las estadísticas de estacionariedad de categoría se pueden realizar fácilmente sobre distribuciones de categoría de los 27 cubos de superposición de la imagen en 3D (en lugar de 9 rectángulos de superposición de la imagen 2D). El criterio de estacionariedad del bloque 13 se aplicaría igualmente para mantener o descartar las imágenes de entrenamiento en 3D. Igualmente, las cuadrículas de imagen de entrenamiento, así como las cuadrículas de restricción de escala y orientación, se pueden exportar como cuadrículas en 3D (en lugar de cuadrículas en 2D).

La metodología basada en computadora de la presente invención también puede extenderse fácilmente al trabajo con imágenes de entrenamiento que tienen valores continuos en lugar de números pequeños de categorías. Por lo tanto, la metodología es adecuada para métodos estadísticos de multipunto que aceptan cuadrículas de imagen de entrenamiento que contienen valores de propiedad (en lugar de categorías).

Las metodologías basadas en computadora de la presente invención han sido probadas en una librería de treinta y ocho imágenes y han mostrado identificar con precisión si la estacionariedad de una Imagen candidata la hace adecuada o no para realizaciones de MPGS. En consecuencia, los geólogos ahorran tiempo y evitan correr realizaciones de MPGS innecesarias usando imágenes de entrenamiento no adecuadas. Más aún, las metodologías basadas en computadora de la presente invención son computacionalmente eficientes, y típicamente se pueden ejecutar en una computadora portátil convencional en solamente unos pocos segundos, mientras uno necesita esperar mucho por los resultados de una realización de algoritmos de MGPS. Finalmente, la salida de resultados de estadísticas de estacionariedad mediante la metodología basada en computadora de la presente invención ha sido totalmente verificada, y se ha

encontrado que es similar al resultado de una interpretación humana basada en una inspección visual de imágenes de entrenamiento.

Se han descrito e ilustrado aquí metodologías basadas en computadora para evaluar automáticamente la estacionariedad de imágenes de entrenamiento para uso en análisis geoestadístico de multipunto. Aunque se han descrito realizaciones particulares de la invención, no se pretende que la invención sea limitada a estas, según se pretende que la invención sea tan amplia en alcance como la técnica lo permita y que la descripción se lea como tal. Por lo tanto los expertos apreciarán que se podrían hacer aún otras modificaciones a la invención proporcionada sin desviarse de su espíritu y alcance como se reivindicó.

REIVINDICACIONES:

1. Un método implementado por computadora que comprende:

analizar datos digitales que representan una imagen para generar al menos una estadística que caracteriza la estacionariedad de la imagen;

derivar al menos un puntaje basado en dicha al menos una estadística;

determinar si dicho al menos un puntaje de satisface dicho criterio de estacionariedad, almacenar o imprimir dicha imagen para usar como una cuadrícula de imagen de entrenamiento estacionaria en el menos un análisis geoestadístico de multipunto.

2. Un método implementado por computadora de acuerdo con la reivindicación 1, en donde:

dicha al menos una estadística comprende una pluralidad de estadísticas que caracterizan la estacionariedad de un campo de orientación extraído de dicha imagen.

3. Un método implementado por computadora de acuerdo con la reivindicación 2, en donde:

dicho campo de orientación se calcula derivando un campo de gradiente a través de una convolución en 2D sobre dicha imagen y luego extrayendo un componente principal del campo de gradiente sobre una ventana deslizante de tamaño fijando usando el análisis de componente principal.

4. Un método implementado por computadora de acuerdo con la reivindicación 3, en donde:

La convolución en 2D emplea filtros de Prewitt.

5. Un método implementado por computadora de acuerdo con la reivindicación 2, en donde:

La pluralidad de estadísticas que caracterizan la estacionariedad del campo de orientación incluye al menos una de las siguientes (i) un primer conjunto de estadísticas que caracterizan la no uniformidad del campo de orientación y provee así una indicación 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 provee así una indicación 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, que provee una indicación que el campo de orientación es similar a lo largo de diferentes zonas de la imagen.

6. Un método implementado por computadora de acuerdo con la reivindicación 2, en donde:

La pluralidad de estadísticas son calculadas sobre una pluralidad de zonas de superposición en la imagen.

7. Un método implementado por computadora de acuerdo con la reivindicación 5, que comprende además:

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

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

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

derivar un puntaje que caracterice la estacionariedad de orientación de la imagen con base en el primer, segundo y tercer puntajes.

8. Un método implementado por computadora de acuerdo con la reivindicación 7, en donde:

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

9. Un método implementado por computadora de acuerdo con la reivindicación 1, en donde:

dicha al menos una estadística comprende una pluralidad de estadísticas que caracterizan la estacionariedad de escala de dicha imagen.

10. Un método implementado por computadora de acuerdo con la reivindicación 9, en donde:

la pluralidad de estadísticas que caracterizan estacionariedad de escala de la imagen, comprende distancias entre un primer conjunto de vectores de característica y un segundo conjunto de vectores de característica, el primer conjunto de vectores de característica derivado de un primer conjunto de imágenes de desplazamiento que son generadas sometiendo la imagen a una pluralidad de operaciones de muestreo dependientes de la rotación, y el segundo conjunto de vectores de característica derivado de un segundo conjunto de imágenes de desplazamiento que son generadas sometiendo un patrón de referencia seleccionado de la imagen a una pluralidad de operaciones de muestreo dependientes de la rotación y la escala.

11. Un método implementado por computadora de acuerdo con la reivindicación 10, en donde:

La pluralidad de operaciones de muestreo dependientes de la rotación emplean muestreo de vecindad circular con transformaciones de orientación; y

la pluralidad de operaciones de muestreo dependientes de la rotación y la escala emplean muestreo de vecindad circular con transformaciones de escala y orientación.

12. Un método implementado por computadora de acuerdo con la reivindicación 11, en donde:

Las transformaciones de orientación se realizan sobre un número predeterminado de pares de factor de afinidad.

13. Un método implementado por computadora de acuerdo con la reivindicación 10, en donde:

el primer conjunto de vectores de característica es computa calculando matrices de co-ocurrencia de nivel de grises sobre el primer conjunto de imágenes de desplazamiento; y

el segundo conjunto de vectores de característica es computa calculando matrices de co-ocurrencia de nivel de grises sobre el segundo conjunto de imágenes de desplazamiento.

14. Un método implementado por computadora de acuerdo con la reivindicación 10, que comprende además:

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

15. Un método implementado por computadora de acuerdo con la reivindicación 14, en donde:

El mapa de afinidad identifica regiones de la imagen y una pareja de factor de afinidad particular asociada con cada región dada, la pareja de factor de afinidad particular identifica, minimizando la distancia entre los vectores de característica del primer conjunto con relación a la región dada y los vectores de característica del segundo conjunto con relación a diferentes parejas de factor de afinidad.

16. Un método implementado por computadora de acuerdo con la reivindicación 14, en donde:

el mapa de afinidad incluye sub-mapas que corresponden cada uno a una pareja de factor de afinidad diferente, en donde un sub-mapa dado caracteriza las distancias entre los vectores de característica del primer conjunto y los vectores de característica del segundo conjunto con relación a la pareja de factor de afinidad particular del sub-mapa dado.

17. Un método implementado por computadora de acuerdo con la reivindicación 16, en donde:

cada sub-mapa comprende una pluralidad de pixeles de escala de grises.

18. Un método implementado por computadora de acuerdo con la reivindicación 16, en donde:

cada sub-mapa comprende una pluralidad de pixeles binarios.

19. Un método implementado por computadora de acuerdo con la reivindicación 14, que además comprende:

mostrar el mapa de afinidad.

20. Un método implementado por computadora de acuerdo con la reivindicación 1, en donde:

dicha al menos una estadística comprende una pluralidad de estadísticas que caracterizan la estacionariedad de distribución de categoría de dicha imagen.

21. Un método implementado por computadora de acuerdo con la reivindicación 1, que comprende además:

al determinar que dicho al menos un puntaje no satisface dicho criterio de estacionariedad, almacenar o imprimir dicha imagen para uso como una cuadrícula de imagen de entrenamiento no estacionaria en al menos un análisis geoestadístico de multipunto.

22. Un método implementado por computadora de acuerdo con la reivindicación 2, que además comprende:

almacenar o imprimir dicho campo de orientación para uso en al menos un análisis geoestadístico de multipunto.

22. Un método implementado por computadora de acuerdo con la reivindicación 14, que además comprende:

almacenar o imprimir dicho mapa de afinidad para uso en al menos un análisis geoestadístico de multipunto.

24. Un método implementado por computadora de acuerdo con la reivindicación 1, que comprende además:

aplicar operaciones de procesamiento de imagen en una imagen candidata para generar una imagen adecuada para el análisis que genera al menos una estadística que caracteriza la estacioneridad de la imagen, dichas operaciones de procesamiento de imagen reducen el número de niveles de escala de grises/color de la imagen candidata mientras mantiene la significancia geológica de las categorías asignadas de la imagen candidata.

RESUMEN DE LA REVELACION

Se provee un método implementado por computadora que caracteriza y verifica automáticamente la estacionariedad de una imagen de entrenamiento para uso en análisis geoestadístico de multipunto. La estacionariedad es preferiblemente caracterizada por medidas estadísticas de estacionariedad de orientación, estacionariedad de escala y estacionariedad de distribución de categoría.

56 172

DECLARACIÓN PARA SOLICITUD DE PATENTE Y PODER DE REPRESENTACION

Como el inventor nombrado más adelante, Yo/nosotros declaramos que:

Mi/nuestra residencia, dirección de correo y ciudadanía son como se declaran a continuación junto con mi/nuestros nombres, y

Yo/Nosotros creo/creemos que soy/somos el inventor original, primero y único de la materia objeto que es reivindicada (si solo un nombre es listado más adelante) o un inventor original y primero de al menos algo de la materia objeto que es reivindicada (si se listan nombres en plural) y para lo cual se busca una patente en la invención titulada

**GENERACION Y VALIDACION DE IMÁGENES DE ENTRENAMIENTO
BASADAS EN COMPUTADORA PARA ANALISIS GEOESTADISTICO DE
MULTIPUNTO**

Cuya descripción

☒ está adjunta a este
☐ fue presentada el
Como Número Serial de Solicitud:
y fue modificada el _____ (si aplica)

Yo/nosotros por medio de la presente declaramos que he/hemos revisado y entendemos el contenido de la descripción identificada anteriormente, incluyendo las reivindicaciones, como se modificaron mediante cualquier adendo referido anteriormente.

Yo/nosotros reconocemos el deber de revelar información que es material para el examen de esta solicitud de acuerdo con el Título 30, del Código de Regulaciones Federales, Sección 1.56 (a).

Solicitud(es) Extranjera(s) Previa(s)

Yo/Nosotros por medio de la presente reivindicamos beneficios de prioridad bajo el Título 35, Código de los Estados Unidos, Sección 119 de cualquier solicitud para patente o certificado de inventor listado a continuación y también he/hemos identificado a continuación cualquier solicitud extranjera para patente o certificado de inventor que tiene una fecha de presentación anterior a la solicitud sobre la cual se reivindica prioridad:

País	Solicitud No.	Presentada (d/m/a)	Emitida (d/m/a)	Prioridad Reivindicada
				S__ N__
				S__ N__

Solicitudes de los Estados Unidos Previas

Yo/Nosotros por medio de la presente reivindicamos el beneficio bajo el Título 35, Código de los Estados Unidos, Sección 120 de cualquier solicitud de los Estados Unidos listada a continuación, en lo que respecta a la materia objeto de cada una de las reivindicaciones de esta solicitud no está revelada en la solicitud previa de los Estados Unidos de la forma provista en el primer párrafo del Título 35, del Código de los Estados Unidos, Sección 112, Yo/nosotros reconoczo/reconocemos el deber de revelar información material definida en el Título 37, Código de Regulaciones Federales, Sección 1.56(a) que sucedió entre la fecha de presentación de la solicitud anterior y la fecha de presentación nacional o PCT de esta solicitud

No. Serial de Solicitud	Fecha de presentación (d/m/a)	Estado (Patentada, Pendiente, Abandonada)

Y yo/nosotros por medio de la presente designo/designamos conjunta y solidariamente, como mi representante(s) y/ agente(s) con poder pleno de sustitución y revocación, para procesar esta solicitud y realizar todas las negociaciones en la Oficina de Patentes y Marcas relacionada aquí, al (los) siguiente(s) representante(s) y agente(s), su(s) número(s) de registro están listados después de su(s) nombre(s).

Dale Gaudier, 28,213; William L. Wang, 39,871; Jody Lynn DeStefanis, 44,653; David P. Gordon, 29,996; Thomas A. Gallagher, 31,358; y David S. Jacobson, 39,235.

Por medio de la presente solicito que toda la correspondencia sea dirigida a:

Customer Number 37003
Intellectual Property Law Department
Schlumberger-Doll Research
36 Old Quarry Rd., Ridgefield, CT 06877

y que todas las llamadas telefónicas sean dirigidas al Departamento de Ley de Propiedad Intelectual en (203) 431-5507, y todas las llamadas de fax sean dirigidas al Departamento de Ley de Propiedad Intelectual en (203) 431-5640.

Yo por medio de la presente declaro (si es un solo inventor) o cada uno de nosotros declaramos (si son inventores conjuntos) que todas las declaraciones hechas aquí de mi propio conocimiento son verdaderas y que todas las declaraciones sobre información y creencia son verdaderas, y que además estas declaraciones se hicieron con el conocimiento que declaraciones falsas deliberadas y de ese tipo son castigables con multa o prisión, o ambas, bajo la Sección 1001 del título 18 del Código de los Estados Unidos y que tales declaraciones falsas deliberadas pueden comprometer la validez de la solicitud o cualquier emisión de patente de la misma.

UNICO O PRIMER INVENTOR

Firma _____ Fecha: _____

Nombre Completo: **Plotr Mirowski**

Residencia: **25 Indian Road, Apt. 1E, New York, New York 10034, USA**

Ciudadanía: **Francesa**

Dirección de Correspondencia: **25 Indian Road, Apt. 1E, New York, New York 10034, USA**

SEGUNDO INVENTOR

Firma _____ Fecha: _____

Nombre Completo: **Daniel Tetzlaff**

Residencia: **9538 Beverlyhill Street, Houston, Texas, 77063, USA**

Ciudadanía: **U.S.A.**

55 179

Dirección de Correspondencia: 9538 Beverlyhill Street, Houston, Texas, 77063, USA

TERCER INVENTOR

Firma _____ Fecha: _____

Nombre Completo: David McCormick

Residencia: 18 Bromfield Road, Acton, Massachusetts 01720, USA

Ciudadanía: U.S.A.

Dirección de Correspondencia: 18 Bromfield Road, Acton, Massachusetts 01720, USA

CUARTO INVENTOR

Firma _____ Fecha: _____

Nombre Completo: Nneka Williams

Residencia: 255 Massachusetts Avenue, Apt. 709, Boston, Massachusetts 02115, USA

Ciudadanía: U.S.A.

Dirección de Correspondencia: 255 Massachusetts Avenue, Apt. 709, Boston, Massachusetts 02115, USA

QUINTO INVENTOR

Firma _____ Fecha: _____


Nombre Completo: Claude Signer

Residencia: 265 Willow Avenue, Somerville, Massachusetts 02115, USA

Ciudadanía: Francesa

Dirección de Correspondencia: 265 Willow Avenue, Somerville, Massachusetts 02115, USA

FIG. 1(A)



10

61- 1722




Figura 2(A)




Figura 2(B)




Figura 2(C)



Figura 2(D)



Figura 2(E)




Figura 3(A)



Figura 3(B)

Componente Y del campo de gradientes usando un operador de Prewitt



Figura 3(C)

Componente X del campo de gradientes usando un operador de Prewitt




Figura 3(D)

Campo de orientación: familia del lateral (60-90) grados, más ruido que el original



Figura 4



**** Figura 4

Figura 5(A)




Figura 5(B)



Figura. 6(A)




Figura 6(B)




Figura 6(c)




Figura 6(D)




Figura 6(E)




Figura 6(F)




Figura 6(G)




Figura 6(H)




Figura 6(I)




Figura 7




Figura 8




Figura 9




FIG. 10(A)




FIG. 10(B)




FIG. 10(C)




FIG. 10(D)




FIG. 10(E)




FIG. 10(F)





FIG. 10(G)



7/192

FIG. 10(H)





FIG. 10(I)

26 / 92

FIG. 10(J)

Escala X x0.67, Escala Y x2




FIG. 10(K)




FIG. 10(L)




FIG. 10(M)




FIG. 10(N)




FIG. 10(O)




FIG. 10(P)




FIG. 10(Q)




FIG. 10(R)





FIG. 10(S)

FIG. 10(T)




FIG. 10(U)




FIG. 10(V)




FIG. 10(W)




FIG. 10(X)




FIG. 10(Y)




Figura 11




Figura 12(A)





Figura 12(B)



Figura 12(C)



29x

Figura 13





Figura 14




93
209

FIG. 15



Recuperar replicados de entrenamiento de $\underline{d}_n$



$$p(u; A | \underline{d}_n) = \frac{1}{5}$$

$$p(u; B | \underline{d}_n) = \frac{4}{5}$$

FIG. 16(A)





FIG. 16(B)



Traducido según mi mejor saber y entender, este día 17 de agosto de 2006, en la ciudad de Bogotá, D.C., por Anita Escobar de Tamayo, Traductora Oficial, Res. 2177 de 1989, Ministerio de Justicia, República de Colombia.

TRADUCTORA OFICIAL
 RES. 2177/89 MINJUSTICIA
Anita Escobar de Tamayo
 ANITA ESCOBAR DE TAMAYO

PA 1488239

THE UNITED STATES OF AMERICA

TO ALL TO WHOM THESE PRESENTS SHALL COME;

UNITED STATES DEPARTMENT OF COMMERCE

United States Patent and Trademark Office

July 10, 2006


THIS IS TO CERTIFY THAT ANNEXED HERETO IS A TRUE COPY FROM THE RECORDS OF THE UNITED STATES PATENT AND TRADEMARK OFFICE OF THOSE PAPERS OF THE BELOW IDENTIFIED PATENT APPLICATION THAT MET THE REQUIREMENTS TO BE GRANTED A FILING DATE UNDER 35 USC 111.

APPLICATION NUMBER: *11/180,191*

FILING DATE: *July 13, 2005*

THE COUNTRY CODE AND NUMBER OF YOUR PRIORITY APPLICATION, TO BE USED FOR FILING ABROAD UNDER THE PARIS CONVENTION, IS *US11/180,191*

By Authority of the
Under Secretary of Commerce for Intellectual Property
and Director of the United States Patent and Trademark Office



N. Williams
N. WILLIAMS
Certifying Officer

212

Schlumberger

113243 U.S. PTO
11/180191
07/13/05

Intellectual Property Law Department
Schlumberger-Doll Research
38 Old Quarry Road
Ridgefield, CT 06877-4108
Phone: (203) 431-5505
Fax: (203) 431-5840
e-mail: jdestefanis@ridgefield.lolfield.slb.com

Via Express Mail Certificate No. EV 058 371 478 US
Customer Number 37003

July 13, 2005

Honorable Commissioner for Patents
P.O. Box 1450
Alexandria, VA 22313-1450

Re: **New Patent Application of:**
Piotr Mirowski, Daniel Tetzlaff, David McCormick,
Nneka Williams, and Claude Signer
Entitled, "COMPUTER-BASED GENERATION AND
VALIDATION OF TRAINING IMAGES FOR MULTIPOINT
GEOSTATISTICAL ANALYSIS"
Our Reference No.: 60.1621 US NP

Sir:

Enclosed, for filing in the U. S. Patent and Trademark Office, is the above-identified, new patent application which includes 42 pages of text, 6 pages of claims (1-24), Abstract, 35 sheets of drawings (Figs. 1-16B), and an unexecuted Declaration.

The filing fee is calculated as follows:


Basic Utility Filing Fee	\$ 300.00
Basic Utility Search Fee	\$ 500.00
Basic Utility Examination Fee	\$ 200.00
Total Claims = 24 Excess over 20 (including Reissues) = 4 X \$50.00	\$ 200.00
Independent Claims = 1 Excess over 3 (including Reissues) = 0 X \$200.00	\$
Application Total Sheets = 84 Excess over 100 = _____ X \$250/50 sheets or fraction thereof	\$
Total Fees	\$ 1,200.00

It is respectfully requested that a filing date bearing today's date be assigned to this application in accordance with 37 CFR §§1.10 and 37 CFR §§1.53, which permits Express Mail filing and late filing of the Oath or Declaration, respectively.

The Commissioner is hereby authorized to charge Deposit Account No. 19-0615 in the amount of \$1,200.00 to cover the above-calculated fees and any other filing fees that may be required under 37 C.F.R. §1.16. Should this amount be incorrect, the Commissioner is hereby authorized to charge or credit any deficiency or overpayment to Deposit Account No. 19-0615

Two copies of this transmittal letter are enclosed for PTO accounting use.

Respectfully submitted,

By 
Jody Lynn DeStefanis
Registration No. 44,653

SCHLUMBERGER TECHNOLOGY CORPORATION

IN THE UNITED STATES PATENT AND TRADEMARK OFFICE

213

In re Application of

MIROWSKI, Piotr et al.

Serial No: To Be Assigned

Filed: July 13, 2005

For: COMPUTER-BASED GENERATION AND VALIDA-
TION OF TRAINING IMAGES FOR MULTIPOINT
GEOSTATISTICAL ANALYSIS

§
§
§
§
§
§
§
§
§
§
§

CUSTOMER NUMBER 37003

Group Art Unit: Unknown

Examiner: Unknown

Attorney Docket No.: 60.1621 US NP

**EXPRESS MAIL CERTIFICATE
UNDER 37 CFR §1.10**

Honorable Commissioner for Patents
P. O. Box 1450
Alexandria, VA 22313-1450

Sir:

Express Mail Label Number: EV 058 371 478 US
Date of Deposit: JULY 13, 2005

I hereby certify that the attached paper(s) are being deposited with the United States Postal Service "Express Mail Post Office to Addressee" service under 37 CFR §1.10 on the date indicated above and is addressed to the Commissioner for Patents, P. O. Box 1450, Alexandria, VA 22313-1450.

(Signature)

(Print Name) Ruth A. Schreiber

Schlumberger-Doll Research
IP Law Department
36 Old Quarry Road
Ridgefield, Connecticut 06877-4108

(203) 431-5507

SCHLUMBERGER TECHNOLOGY CORPORATION

PATENT APPLICATION

COMPUTER-BASED GENERATION AND VALIDATION OF TRAINING IMAGES FOR MULTIPOINT GEOSTATISTICAL ANALYSIS

Inventors:

MIROWSKI, Piotr, a citizen of France, residing at
25 Indian Road, Apt. 1E, New York, New York 10034,
USA;

TETZLAFF, Daniel, a citizen of the United States of
America, residing at 9538 Beverlyhill Street, Houston,
Texas 77063, USA;

McCORMICK, David, a citizen of the United States
of America, residing at 18 Bromfield Road, Acton,
Massachusetts 01720, USA;

WILLIAMS, Nneka, a citizen of the United States of
America, residing at 255 Massachusetts Avenue, Apt.
709, Boston, Massachusetts 02115, USA; and

SIGNER, Claude, a citizen of France, residing at
265 Willow Avenue, Somerville, Massachusetts 02144,
USA

Assignee: SCHLUMBERGER TECHNOLOGY CORPORATION
with offices at:
36 Old Quarry Road
Ridgefield, CT 06877-4108
Incorporated in the State of Texas

Correspondence Address:

SCHLUMBERGER-DOLL RESEARCH
Intellectual Property Law Department
36 Old Quarry Road
Ridgefield, CT 06877-4108

COMPUTER-BASED GENERATION AND VALIDATION OF TRAINING IMAGES FOR MULTIPOINT GEOSTATISTICAL ANALYSIS

BACKGROUND OF THE INVENTION

Field of the Invention

[0001] This invention relates broadly to statistical analysis of random variables that simulate a property field. More particularly, this invention relates to multipoint geostatistical methods and simulations.

State of the Art

[0002] Geostatistics is a discipline concerned with spatially distributed random variables (also called "regionalized variables"), usually applied to problems in the earth sciences, such as estimation of mineral reserves and delineation of mineral deposits, hydrocarbon reservoirs, and aquifers. Multipoint (or multiple-point) geostatistics (MPGS) differs from the rest of geostatistics primarily in that it characterizes spatial variability using patterns (sets of points) that contain more than two points.

[0003] One of the goals of multipoint geostatistics is simulation, namely the generation of numerical values along a line, on a surface, or in a volume, such that the set of values honors certain given spatial correlation properties (usually derived from a data set called "analog" or "training image") while optionally (in the case called "conditional simulation") honoring predetermined data. In practice, the "analog" may be, for example, a well-known rock volume that is statistically similar to a yet poorly known oil reservoir being delineated, and the predetermined data to be honored may be lithology observations at wells, or probabilities of lithologies derived from seismic data. In this manner, MPGS simulations honor absolute or so-called "hard" constraints from data acquired in wells or outcrops, and conditional or "soft" constraints from seismic data, facies probability fields, and rotation and affinity (or scale) constraint grids. Such data

216

are used in a stochastic modeling process to generate one-dimensional (1D), two-dimensional (2D) and/or three-dimensional (3D) maps of geological facies or rock properties. Since there is a random component involved in MPGS simulations, individual realizations of property fields created by MPGS algorithms differ, but the ensemble of realizations provide geoscientists and reservoir engineers with improved quantitative estimates of the spatial distribution and uncertainty of geological facies or rock properties in a modeled reservoir volume.

[0004] Multipoint geostatistical methods have been recently demonstrated to be computationally feasible and have been tested on real datasets as set forth in i) Strebelle, "Conditional Simulation of complex geological structures using multiple-point statistics," *Mathematical Geology*, v. 34, n. 1, 2002, pp. 1-22, ii) Strebelle et al., "Modeling of a deepwater turbidite reservoir conditional to seismic data using principal component analysis and multiple-point geostatistics," *SPE Journal*, Vol. 8, No. 3, 2003, pp. 227-235, and iii) Liu et al., "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] Traditional geostatistical methods rely upon a variogram to describe geologic continuity. However, a variogram, which is a two-point measure of spatial variability, cannot describe realistic, curvilinear or geometrically complex patterns. Multipoint geostatistical methods use a training image (instead of a variogram) to account for geological information. The training image provides a conceptual description of the subsurface geological heterogeneity, containing possibly complex multipoint patterns of geological heterogeneity. Multipoint statistics simulation anchors these patterns to well data (and/or outcrop data) and to the seismic-derived information (and/or probability field information or constraint grid(s)).

[0006] The training image often, but not necessarily, has a low-resolution (i.e. typically a few hundred pixels a side). Each pixel of the training image has a level (which can be a binary value, a grayscale value or a color value) associated therewith. The level at each pixel is referred to herein as a category. Typically,

212

there are around 5 to 10 possible categories at each pixel of the training image, but this number could be greater or smaller. The shapes of geological element(s) defined by the training image represent a model of real geological elements, with each category typically representing a different geological facies or a different kind of geological body.

[0007] Geostatistics relies on the well-known concept of random variables. In simple terms, reservoir properties at various grid locations are largely unknown or uncertain; hence each property of interest at each grid location is turned into a random variable whose variability is described by a probability function. In order to perform any type of geostatistical simulation, one requires a decision or assumption of stationarity. In multipoint geostatistical methods, the use of training images is bound by the principle of stationarity as described by Caers et al., "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. In the case of 2D or 3D reservoir modeling, a random variable or random process is said to be stationary if all of its statistical parameters are independent of its location in space (invariant according to any translation). In the case of training images, this stationarity can consist, but is not limited to,

- orientation stationarity, where directional elements do not rotate across the training image; and
- scale stationarity (where the size of elements on the image does not change across the training image).

[0008] Although the concept of stationarity is referred to in Caers et al. paper entitled "Multiple-point geostatistics: a quantitative vehicle for integrating geologic analogs into multiple reservoir models," this paper fails to disclose a methodology for automatically estimating and validating the stationarity of a given training image to ensure that that training image is appropriate for multipoint geostatistical methods.

SUMMARY OF THE INVENTION

[0009] It is therefore an object of the invention to provide a methodology for automatically estimating and validating the stationarity of a given training image to ensure that the training image is appropriate for multipoint geostatistical methods.

[0010] It is another object of the invention to provide data structures that characterize properties of a training image, which can be used in multipoint geostatistical methods.

[0011] In accord with these objects, which will be discussed in detail below, a computer-implemented method is provided that automatically characterizes and verifies stationarity of a training image for use in multipoint geostatistical analysis. The stationarity of the training image is preferably characterized by statistical measures of orientation stationarity, scale stationarity, and category distribution stationarity.

[0012] It will be appreciated that the computer-implemented methods of the present invention provide an automatic and accurate determination of whether or not a candidate training image is stationary and thus is suitable for MPGS realizations requiring such stationary training images. By consequence, geologists employing the computer-implemented methods of the present invention save time and avoid running unnecessary MPGS realizations using unsuitable training images.

[0013] According to the preferred embodiment of the invention, the statistical measures that characterize the orientation stationarity of the training image include at least one of the following: (I) a first set of statistics that characterizes nonuniformity of the orientation field and thus provide an indication that there is one or several preferential directions in the orientation grid, (II) a second set of statistics that characterizes the normality of the distribution of directions in the orientation grid and thus provides an indication that there is a dominant direction in the orientation field, and (III) a third set of statistics that characterizes the repeatability of the orientation field, which provides an indication that the orientation field is similar across different zones of the image. The statistical

measures that characterize the scale stationarity of the training image preferably include distances between a first set of feature vectors and a second set of feature vectors. The first set of feature vectors is derived from a first set of displacement images that are generated by subjecting the image to a plurality of rotation-dependent sampling operations. The second set of feature vectors is derived from a second set of displacement images that are generated by subjecting a reference pattern selected from the image to a plurality of rotation- and scale-dependent sampling operations.

[0014] Additional objects and advantages of the invention will become apparent to those skilled in the art upon reference to the detailed description taken in conjunction with the provided Figures.

BRIEF DESCRIPTION OF THE DRAWINGS

[0015] FIG. 1(A) is a block diagram of a computer processing system that embodies the methodology of the present invention.

[0016] FIG. 1(B) is a flow chart illustrating the workflow of the computer-based methodology for the automatic generation and verification of training images and subsequent multipoint geostatistical analysis based thereon in accordance with the present invention.

[0017] FIGS. 2(A) - 2(E) are a sequence of images that illustrate the image processing operations performed on a candidate image as part of the workflow of FIG. 1(B); in this example, the candidate image is an aerial color photograph of a river delta.

[0018] FIGS. 3(A) - 3(D) are a sequence of images that illustrate the image processing operations that extract an orientation field for a training image category as part of the workflow of FIG. 1(B); FIG. 3(A) is the training image; FIG. 3(B) is an image illustrating the Y-component of the 2D gradient field that is generated by applying the Prewitt filter G_y over the training image category of

220

FIG. 3(A); FIG. 3(C) is an image illustrating the X-component of the 2D gradient field that is generated by applying the Prewitt filter G_x over the representative training image category of FIG. 3(A); and FIG. 3(D) is an image showing the orientation field of the training image category of FIG. 3(A).

[0019] FIG. 4 is a flowchart illustrating operations that generate orientation stationarity statistics and a score based thereon as part of the workflow of FIG. 1(B).

[0020] FIGS. 5(A) and 5(B) are graphs that illustrate the probability density function of a Von Mises distribution.

[0021] FIGS. 6(A) - 6(I) are diagrams that illustrate the partitioning of a training image category into overlapping zones; these overlapping zones are used in computing orientation stationarity statistics (and a score based thereon), scale stationarity statistics (and a score based thereon) and category distribution stationarity statistics (and a score based thereon) as part of the workflow of FIG. 1(B).

[0022] FIG. 7 is a flowchart illustrating operations that generate scale stationarity statistics and a score based thereon as part of the workflow of FIG. 1(B).

[0023] FIG. 8 is a graph illustrating a circular 4-th order neighborhood sampling system.

[0024] FIG. 9 is a graph illustrating a circular 4-th order neighborhood sampling system adapted for rotation-and-scale-dependent sampling; the rotation-dependent sampling is used to sample the training image and extract feature vectors from the training image; the rotation-and-scale-dependent sampling is used to sample a reference pattern and extract feature vectors from the reference pattern; these feature vectors are analyzed to generate scale stationarity statistics and a score based thereon as part of the workflow of FIG. 1(B).

221

[0025] FIGS. 10(A) - 10(Y) are diagrams illustrating a set of 25 affinity factor couples; these affinity factor couples are used in computing scale stationarity statistics and a score based thereon as part of the workflow of FIG. 1(B).

[0026] FIG. 11 is a schematic diagram illustrating the operations that compute scale stationarity statistics and an affinity map based thereon as part of the workflow of FIG. 1(B).

[0027] FIG. 12(A) is an exemplary training image, which is derived by copying/pasting the upper left corner (outlined by a rectangle) into the other parts of the image with different affinity transformations applied thereto.

[0028] FIG. 12(B) is a set of affinity maps that illustrate the distance between the feature vectors for corresponding parts in the training image and the reference pattern over different affinity factor couples for the training image of FIG. 12(A) with the upper left corner selected as the reference pattern; the pixels of each 2D image are gray-scale with the distances represented by the pixels quantized into a gray-scale range of values.

[0029] FIG. 12(C) is a set of affinity maps that illustrate the distance between the feature vectors for corresponding parts in the training image and the reference pattern over different affinity factor couples for the training image of FIG. 12(A) with the upper left corner selected as the reference pattern; the pixels of each 2D image are binary with the distances represented by the pixels assigned to a binary range of values; the closest distances are assigned to one binary value (i.e., black), while the other distances are assigned to the other binary value (i.e., white).

[0030] FIG. 13 is a graph that illustrates the measurement of a spread of points in a 2-dimensional space; this measurement is used to compute scale stationarity statistics and a score based thereon as part of the workflow of FIG. 1(B).

[0031] FIG. 14 is a diagram illustrating a three-dimensional plot of the stationarity scores for a number of training images; the axes correspond to three

222

different stationarity measures with the X-axis corresponding to the category distribution stationarity measure, the Y-axis corresponding to the scale stationarity measure, and the Z-axis corresponding to the orientation stationarity measure; regions of this 3-D space can be defined as delimiting "good" training images and used as a decision criterion to automatically ascertain whether the particular training image is sufficiently stationary for use in multiple-point geostatistical analysis requiring such stationarity.

[0032] FIG. 15 is a schematic diagram illustrating the SNESIM method of geostatistical analysis and simulation.

[0033] FIG. 16(A) is a schematic diagram illustrating the SIMPAT method of geostatistical analysis and simulation.

[0034] FIG. 16(B) is a schematic diagram illustrating an extension of the SIMPAT method which employs "feature-based" geostatistics.

DETAILED DESCRIPTION OF THE PREFERRED EMBODIMENT

[0035] FIG. 1(A) is a functional block diagram of a general purpose computer system 100 that embodies the present invention. The computer system 10 may include a work station (or high performance personal computer) that performs the relevant computations and decision logic as discussed below, e.g., training image processing, training image stationarity statistics generation and evaluation, and multi-point statistical analysis based thereon. For example, the computer system 10 may include a display device 12 and user input devices such as a keyboard 14 and mouse 16. The computer system 10 also includes memory 18 (e.g., persistent memory such as a magnetic hard disk drive as well as non-persistent memory such as one or more DRAM modules) that stores software application(s) that are executed on a processor 20 to perform the relevant computations and decision logic as discussed below, e.g., training image processing, training image stationarity statistics generation and evaluation, and multi-point statistical analysis based thereon. Such software applications, which comprise a programmed sequence of instructions and data, are typically stored on one or more optical disks that are loaded into the memory 18 by an optical disk drive

223

(not shown) for persistent storage therein. Alternatively, such software applications can be loaded into the memory 18 over a network connection (e.g., an Internet connection) or other suitable means for persistent storage therein. In the description below, the "image" refers indistinctly to either a line or a surface or a volume, and consists of a contiguous array of equal pixels, each of which may contain a value (or number).

[0036] FIG. 1(B) illustrates a workflow that embodies a computer-based methodology for the automatic generation and the validation of training images and multipoint geostatistical simulations based thereon in accordance with the present invention. Candidate images that are used for the generation of training images are stored in an image database 101, which can be realized by any kind of electronic, optical, or magnetic storage. In block 103, a candidate image is imported from the image database 101. At this point, the candidate image can be any kind of black and white, grayscale, color, or multispectral image, and can be of any definition (resolution). For simplicity of description, the candidate image is referred to as a "high-resolution" image in block 105.

[0037] In block 107, the candidate image of block 105 is processed to adjust the number of categories of the pixels of the image if desired and to adjust its resolution if desired. Typical multi-point geostatistical methods require a training image with a small number of categories, for instance less than 11. Often, the dimensions of the training image must be a few hundred pixels a side. The task of reducing the number of grayscale/color levels of the candidate image while keeping geological significance of the assigned categories of the candidate image is of variable difficulty and depends upon the complexity and quality of the candidate image, including the presence of noise and illumination effects. The list of image processing operations that can be used as part of this step includes, but is not limited to, mathematical morphology operations on images, color or gray-level histogram thresholding or clustering, low-pass or high-pass image filtering. Often, the desired result can be achieved only through a combination of successive image processing operations on the original image. A graphical user interface may be provided that enables a user to interconnect such blocks, visualize such interconnections by a graph, and then save the interconnected

224

image processing workflow for subsequent use. The resultant image generated by the image processing workflow of block 107 is referred to as a "low resolution, few category" training image in block 109. The dimensions and categories of the training image of block 109 match the dimensions and categories required for subsequent multipoint geostatistical methods (block 119).

[0038] FIGS. 2(A) - 2(E) illustrate an example of the image processing workflow of block 107 on a candidate image that is an aerial color photograph of a river delta. FIG. 2(A) is the grayscale copy of the aerial color photograph. FIG. 2(B) is the result of the removal of the illumination effect on the image of FIG. 2(A) by the application of a morphological operation. FIG. 2(C) is the result of a color segmentation of the image of FIG. 2(B) and of the removal of large connected areas (here the river and the sea) by a flood-fill technique. In FIG. 2(D), only the grayscale level corresponding to rivers has been retained, and the two other grayscale levels are merged together. FIG. 2(E) is a cropped highlight of the image of FIG. 2(D) and shows the river channel pattern that is retained for the purpose of a candidate training image for multi-point geostatistical methods. This pattern has 2 categories, the river and the background.

[0039] In block 111, the stationarity of the training image of block 109 is estimated. Such operations derive stationarity statistics which characterize the stationarity of the training image. Preferably, such statistics characterize the stationarity of the orientation field (block 111A), the stationarity of the image scale (block 111B) and the stationarity of the distribution of categories (block 111C) for the training image of block 109.

[0040] In block 113, the stationarity statistics derived in block 111 are analyzed to determine if the training image of block 109 satisfies a set of predetermined constraints which dictate whether or not the training image should be used in subsequent multi-point geostatistical analysis (e.g., block 119). If the stationarity statistics satisfy such predetermined constraints, the training image is added to a training image database 115, which can be realized by any kind of electronic, optical, or magnetic storage. This training image can be accessed from the database 115 (or output directly from block 113) for use in a multi-point

225

geostatistical analysis (block 119). Such operations may involve formatting the training image as a training image grid (block 117) in accordance with the format required by the multi-point geostatistical analysis (block 119).

[0041] If it is determined in block 113 that the stationarity statistics do not satisfy the predetermined constraints, the user selects whether or not the non-stationary training image should be added to the training image database 115 (block 121) or discarded (block 123). The non-stationary training image can be accessed from the database 115 (or output directly from block 121) for use in multi-point geostatistical analysis (block 127). Such operations may utilize the non-stationary training image as the basis for a non-stationary training image grid (blocks 125A, 127A), a scale constraint grid (blocks 125B, 127B), or an orientation constraint grid (blocks 125C, 127C).

[0042] For non-stationary images (e.g., those not discarded in block 123), the operations can recursively jump back to block 107 wherein different image processing techniques can be applied to extract other features from the candidate image of block 105 in order to produce a training image that meets the stationarity criteria (blocks 109-113).

[0043] FIG. 4 illustrates the operations of block 111A that characterize the stationarity of the orientation field of the training image of block 109. It is assumed that for each training image, the categories of the training image correspond to different geological elements. In order to separate the orientation stationarity statistics by category and by kind of geological element, each category is isolated and the orientation field and statistics derived therefrom are derived for the particular category. In order to isolate a particular category, pixels that are from any other category are all assigned to the same background category. Stationarity statistics by category can then be averaged or weighted according to the significance that the user wants to attribute to them.

[0044] The operations on the training image (labeled block 401) begin by initializing a counter (variable "k") to 1 (block 403) and then transforming a copy of the training image such that the category corresponding to the counter k (i.e.,

226

the k^{th} category) is isolated from the other categories (block 405). This image is referred to as a "training image category" below.

[0045] In blocks 407 and 409, the orientation field for the training image category is derived. In the preferred embodiment, the orientation field is calculated by first computing the gradient field of the training image category using a 2D convolution, such as the "vertical" and "horizontal" Prewitt filters, and then extracting the first principal component of the gradient field over a sliding window of fixed size (which is referred to as the "kernel") using principal component analysis. Such analysis is described in detail in Feng X., "Analysis and Approaches to Image Local Orientation Estimation," thesis submitted for an MSc in Computer Engineering at University of California at Santa Cruz, 2003, and in Randen et al., "Three-Dimensional Texture Attributes for Seismic Data Analysis," Schlumberger Stavanger Research, SEG 2000 Expanded Abstracts, 2000, herein incorporated by reference in their entireties. The "vertical" Prewitt

filter $G_v = \begin{bmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{bmatrix}$ emphasizes "horizontal" edges (i.e., edges along the X

direction). The "horizontal" Prewitt filter $G_h = \begin{bmatrix} 1 & 0 & -1 \\ 1 & 0 & -1 \\ 1 & 0 & -1 \end{bmatrix}$ emphasizes "vertical"

edges (i.e., edges along the Y direction).

[0046] The gradient field is comprised of a 2D vector for each pixel of the training image category. Using principal component analysis, the first principal component of the gradient field is extracted over a circular mask scanned over the image. This is similar to computing the eigenvectors and eigenvalues of the

matrix $T = \frac{1}{n} \sum_{i=1}^n x_i x_i^T$. The circular mask is obtained from a square window

(kernel) of fixed size N where the pixels are given a weight $W(x,y)$ like in the 2D Gaussian window $W(x,y)$ where

227

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

[0047] The principal component analysis generates two attributes: (I) the unit principal vector $V/|V|$ (either as a value in radians or as x and y components); and (II) its associated principal value s_1 , which is also the principal vector modulus and which highlights strong isotropic trends. It must be noted that since the gradient vectors are orthogonal to the desired image orientation, the principal direction must be rotated by $\pi/2$ radians. The orientation field is defined by the unit principal vector and its associated principal value (or magnitude) at fixed intervals, with typical values of 64 pixels for the size of the kernel or mask, and 16 pixels for the spacing of two consecutive samples. The orientation field can be represented either by the angle and the magnitude of the principal unit vectors (where all the angles are computed modulo 180 degrees) or the X and Y components of the unit principal unit vectors and associated principal values.

[0048] FIGS. 3(A) - 3(D) are a sequence of images that illustrate the image processing operations that extract an orientation field for a training image category as part of the workflow of FIG. 1(B). FIG. 3(A) is an exemplary training image category. FIG. 3(B) is an image illustrating the Y-component of the 2D gradient field that is generated by applying the Prewitt filter G_y over the training image category of FIG. 3(A). FIG. 3(C) is an image illustrating the X-component of the 2D gradient field that is generated by applying the Prewitt filter G_x over the training image category of FIG. 3(A). The principal component of the orientation vectors can be computed in sliding overlapping regularly-sampled windows (also called the orientation kernel). FIG. 3(D) is an image showing the orientation field, where the orientation kernel is of size 64x64 pixels and is sampled every 16 pixels.

[0049] Returning to FIG. 4, in block 411, the orientation field generated in block 409 is used to derive statistics that characterize the axial orientation of the training image category and one or more scores associated therewith. Preferably, such statistics are distribution parameters that estimate the Von-

Mises distribution of the orientation field and the score(s) associated therewith that characterize one or more of the following: (i) the uniformity/nonuniformity of circular data distribution of the orientation field, which provides an indication that there is one or several preferential directions on the image, (ii) normality of circular data distribution of the training image category, which provided an indication that there is a dominant direction of the orientation field and (iii) repeatability of the orientation field, which provides an indication that the orientation field is similar across different zones on the image.

[0050] In block 413, it is determined whether the counter "k" corresponds to the last category (K) of the training image. If not, the counter "k" is incremented by one (i.e., $k = k + 1$) in block 415 and the operations return to block 405 to isolate the next category of the training image and compute the orientation stationarity statistics for the next category (blocks 407-411). When the last category has been processed ($k=K$ in block 413), the operations continue to block 417 to display the results of the orientation stationarity processing of blocks 407-411 for each category of the training image. Stationarity statistics by category can then be averaged or weighted according to the significance that the user wants to attribute to them for subsequent processing and decision making.

[0051] In the preferred embodiment, it is assumed that the orientation field follows a circular normal distribution. In this case, the angles of the orientation vectors modulo 180 degrees are important, and the magnitudes of such vectors are irrelevant. Thus, the distribution must have an axial symmetry. The hypothesis of normality is of course restrictive but can be justified by the fact that the orientation field is computed with large kernels. This provides an hypothesis of a 2-wrapped Von Mises distribution, which is described in more detail in Mardia, "Statistics of Directional Data", Academic Press, New York, 1972, pp.57-69, herein incorporated by reference in its entirety. The Von Mises distribution is controlled by two parameters, the scale parameter κ and the location parameter μ , and it follows the probability density function (PDF)

$$f(\theta, \mu, \kappa) = \frac{1}{2\pi I_0(\kappa)} e^{\kappa \cos(2(\theta - \mu))} \text{ as shown in FIGS. 5(A) and 5(B). The variable } \kappa$$

229

is the concentration (an inverse measure of the "spread" of the orientation angle θ) and the variable μ is their mean direction. The function $I_0(\kappa)$ is the zero-order Bessel function defined by $I_0(\kappa) = \frac{1}{2\pi} \int_0^{2\pi} e^{\kappa \cos \theta} d\theta$. The Von Mises distribution is by nature unimodal, unless the concentration κ equals 0 when it becomes uniform. All the statistics and tests relative to the Von Mises distribution can be obtained by multiplying the angles by 2. The simple Von Mises distribution follows the probability density function $f(\theta, \mu, \kappa) = \frac{1}{2\pi I_0(\kappa)} e^{\kappa \cos(\theta - \mu)}$.

[0052] Under the assumption of a unimodal normally distributed orientation field, the following formulas are preferably used to obtain an estimate $\tilde{\mu}$ of the circular mean μ

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

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

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

$$\tilde{\mu} = \text{sign}(S) \times \frac{\cos^{-1}\left(\frac{\bar{R}}{C}\right)}{2}$$

Here C and S are the direction cosines and sines, and $\bar{R}$ is defined as the mean resultant length and is directly related to the concentration κ . These equations are described in detail in Rock, "Lecture Notes in Earth Sciences 18 – Numerical Geology," Springer Verlag, 1988, herein incorporated by reference in its entirety. Note that the angles are doubled beforehand, and thus must be divided by two at the end. An estimate $\tilde{\kappa}$ can be derived from the maximum likelihood estimation. Alternatively, the estimate $\tilde{\kappa}$ can be derived using the following approximation

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

[0053] Estimation of the orientation stationarity of the training image category requires analysis that determines whether the distribution of the orientation field vectors is self-similar in different regions of the training image category. For this reason, nonuniformity and normality tests are done on the whole image and on each one of a plurality of overlapping zones. In the example shown in FIGS. 6(A) - 6(I), the training image category is partitioned into 9 overlapping zones, which are labeled Z1, Z2, ... Z9. In this configuration, there are $1 + 9 = 10$ different tests. In order to test an image for orientation stationarity, three (3) factors are empirically defined: (I) the nonuniformity of the orientation field, which provides an indication that there is one or several preferential directions in the orientation field, (II) the normality of the distribution of directions in the orientation field, which provides an indication that there is a dominant direction in the orientation field, and (III) the repeatability of the orientation field, which provides an indication that the orientation field is similar across different zones of the image. The repeatability test consists of comparing the orientation statistics taken over all the couples of zones. Using the 9 zones shown in FIGS. 6(A) - 6(I), there are $C_9^2 = 36$ combinations of those couples.

[0054] The nonuniformity of the circular data distribution of the orientation field is estimated with a Rayleigh test based on the value of the mean resultant length $\bar{R}$ described above with two hypotheses as follows: (I) H_{A0} : null hypothesis of uniformity, i.e. the orientation field does not have a preferential direction and could have been drawn from a random distribution; and (II) H_{A1} : nonuniformity of the circular data distribution of the orientation field. For small values of $N \leq 100$, the test is simply $\bar{R} > K$, and the critical values for $\Pr(\bar{R} \geq \bar{R}_0) = \alpha$ with the following levels of confidence $\alpha \in \{1\%, 5\%, 2.5\%, 1\%, 0.1\%\}$ are table based and preferably derived from the table on page 300 of Mardia, "Statistics of

231

Directional Data", Academic Press, New York, 1972. For $N > 100$, the test is based on: $2N\bar{R}^2 > K$, where $2N\bar{R}^2$ is distributed as χ^2_1 . The critical values for $\alpha \in \{10\%, 5\%, 2.5\%, 1\%, 0.1\%\}$ are $\chi^2_1 \in \{4.605, 5.991, 7.378, 9.21, 13.816\}$. As a result of this test, the value of the confidence level α that yields the critical value closest to the tested value is returned. The percentage of certainty for nonuniformity is then given as $1 - \alpha$. All the 9 zones and the whole orientation field are tested for uniformity. The final score for the nonuniformity for the whole image at a given scale (or size of the orientation kernel) is

$$\text{nonuniformity} = \frac{(1 - \alpha_{\text{max}}) + \sum_{k=1}^9 (1 - \alpha_{z_k})}{10}$$

[0055] The major limitation of this Rayleigh test is its hypothesis of normality of the circular distribution that allows the computation of $\bar{R}$, which is the mean resultant length on which the test statistic is based. Hence, if the distribution has, for example, two obvious modes that are 40-60 degrees apart, the test might give a high probability of nonuniformity because of a relatively high value of $\bar{R}$. Consequently, this test cannot be considered as a test assessing the hypothesis of uniformity vs. unimodality. A preferred approach is to set the nonuniformity score of a given zone to 0 if the test cannot be done because of lack of normality of the distribution on that zone.

[0056] The normality of the circular data distribution of the orientation field is estimated with a goodness of fit test that determines whether the assumption of a Von Mises distribution is correct, and thus confirms a normal distribution that has a preferential direction (theoretically unimodal according to its PDF) or which can become uniform for an extreme value of $\bar{R} = 0$. The test has two hypotheses: (i) H_{B0} : null hypothesis of goodness of fit with the 2-wrapped Von Mises distribution (i.e., normality of the distribution); and (ii) H_{B1} : not a Von Mises distribution (i.e., not a normal distribution). A classical goodness-of-fit Chi-Square test can be used by comparing the circular histogram $\{O_i\}_{i \in [1, 18]}$ of the measured orientation

232

field with the theoretical histogram $\{E_i\}_{i \in [1,18]}$ that would be given by a 2-wrapped Von-Mises distribution with the same estimated mean direction $\tilde{\mu}$ and the concentration parameter $\tilde{\kappa}$ and computed over the same bins $\theta_{i \in [1,18]}$. The measured axial data are between $[-90, 90\text{deg}]$ and are binned into 18 bins $\{O_i\}_{i \in [1,18]}$ of width 10deg that have the following bin centers:

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

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

The test criterion is $\chi^2 > \chi_{\alpha, \nu}^2$ where $\chi^2 = \sum_{i=1}^{18} \frac{(O_i - E_i)^2}{E_i}$. For the Chi-Square test, $\nu = 18 - 2 - 1 = 15$ degrees of liberty is used (we are comparing 18-bins histograms and the Von Mises distribution has 2 parameters, the location and the scale). The critical values for

$$\alpha \in \{99.5\%, 99\%, 97.5\%, 95\%, 90\%, 75\%, 50\%, 25\%, 10\%, 5\%, 2.5\%, 1\%, 0.5\%\} \text{ are } \chi_{15, \alpha}^2 \in \{4.60, 5.23, 6.26, 7.26, 8.55, 11.04, 14.34, 18.25, 22.31, 25.00, 27.49, 30.58, 32.80\}$$

As a result of the test, the value of the confidence level α that yields the critical value closest to the tested value is returned. All the 9 zones and the whole orientation field are tested for normality. The final score for the normality for the whole image at a given scale (or size of the orientation kernel) is

$$normality = \frac{\alpha_{image} + \sum_{i=1}^9 \alpha_{z_i}}{10}$$

[0057] The Chi-Square goodness-of-fit test has limitations due to the binning of circular data into a histogram, limitations that become more apparent when the value of the estimated concentration becomes very high. In that case, the test might give a very low or null confidence level for the normality test whereas the data are obviously unimodal. Consequently, two conditions can be set that

253

automatically yield a confidence level $\alpha = 100\%$: e.g., (i) $\tilde{\kappa} > 20$; and (ii) $\text{card}(\{O_i\}_{i \in [1, N]} > 0) < 3$. Correction of a numerical artifact due to the binning is also provided - that is that for a given bin i , a very small value of the estimated observation $0 < E_i \ll 1$ and a real observation $O_i = 1$ (with the total number of observations being relatively high) will contribute a large number to the χ^2 test statistic, therefore making the test fail. Since inadequate binning mostly contributes to this result, the contribution of this particular real observation to the χ^2 test statistic can be set to zero.

[0058] The repeatability of the distribution of the orientation field is estimated with a two part test. The first test is a non-parametric test that compares two distributions taken from two zones of the image. The test employs two hypotheses: (i) H_{C0} : null hypothesis of having the two samples from the same population (distribution); and (ii) H_{C1} : the two samples are not from the same distribution. Here, the two samples that contain respectively n_1 and n_2 observations, where $N = n_1 + n_2$. Both samples are combined and then ordered. The sets $\{a_i\}_{i \in [1, N]}$ and $\{b_j\}_{j \in [1, N]}$ are defined as follows. The set $\{a_i\}_{i \in [1, N]}$ is comprised of the numbers of observations from the first sample among the first i order statistics of the combined sample. The set $\{b_j\}_{j \in [1, N]}$ is comprised of the numbers of observations from the second sample among the first j order statistics of the combined sample. A U^2 value is calculated as follows

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

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

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

The critical values of U_{n_1, n_2}^2 for levels of confidence of $\alpha \in \{10\%, 5\%, 1\%, 0.1\%\}$ are given on page 314 of Mardia, "Statistics of Directional Data", Academic Press, New York, 1972. Details of this two-sample Watson U^2 test is described in

234

Mardia, "Statistics of Directional Data", Academic Press, New York, 1972, pp. 201-203, herein incorporated by reference in its entirety.

[0059] . . The two-sample U^2 test often fails when the spread of directions is very narrow, probably because the directions are not regularly interleaved. As an alternative that also is sensitive to very narrow distributions of angles $\{\theta_i\}_{i \in [1, n_1]}$ and $\{\theta_j\}_{j \in [1, n_2]}$, the following test can be used:

```

if ( [ range( {θi }i ∈ [1, n1] ) < 40° ] and [ range( {θj }j ∈ [1, n2] ) < 40° ] )
    α = { 0 if ( [ min( {θi }i ∈ [1, n1] ) < min( {θj }j ∈ [1, n2] ) ] and [ max( {θi }i ∈ [1, n1] ) < min( {θj }j ∈ [1, n2] ) ] )
        0 if ( [ min( {θj }j ∈ [1, n2] ) < min( {θi }i ∈ [1, n1] ) ] and [ max( {θj }j ∈ [1, n2] ) < min( {θi }i ∈ [1, n1] ) ] )
        1 otherwise
    else
        execute the Watson's U2 non-parametric test
    endif

```

Once the test is executed for all the $C_2^2 = 36$ possible pairs of zones, the first part of the repeatability score is computed as follows:

$$repeatability_1 = \frac{\sum_{i \in [1, 9]} \sum_{j \in [1, 9]} a_{z, x_j}}{C_2^2}$$

[0060] The second test that estimates the repeatability of the distribution of the orientation field is a parametric test that compares two distributions taken from two zones of the image under the assumption that both distributions are Von Mises. The first part of this parametric test is an equal concentration test with a confidence level α_r . In this first part, for $\bar{R} < 0.45$, the statistic

$$Z = \frac{\frac{2}{\sqrt{3}} [\varphi(\bar{R}_1) - \varphi(\bar{R}_2)]}{\sqrt{\frac{1}{n_1 - 4} + \frac{1}{n_2 - 4}}} \text{ (where } \varphi(\bar{R}) = \sin^{-1} \left(\min \left\{ 2\bar{R} \sqrt{\frac{3}{8}}, 1 \right\} \right) \text{), is computed and}$$

235

compared with the standard normal deviation. Instead of looking up critical values in tables, the confidence level is computed from the statistic Z using the

cumulative normal distribution function $D(Z) = \frac{1 + \operatorname{erf}\left(\frac{Z}{\sqrt{2}}\right)}{2}$. Since the critical region consists of equal tails, the confidence level is obtained by writing

$$\alpha_r = 1 - 2 \times |D(Z) - 0.5|: \text{ For } 0.45 \leq \bar{R} < 0.7, \text{ the statistic } Z = \frac{f(\bar{R}_1) - f(\bar{R}_2)}{0.893 \sqrt{\frac{1}{n_1 - 3} + \frac{1}{n_2 - 3}}}$$

(where $f(\bar{R}) = \ln \left[x + \sqrt{1 + x^2} \right]$, where $x = \frac{\bar{R} - 1.0894}{0.2578}$) is computed and compared with the standard normal deviation. Instead of looking up critical values in the tables, the confidence level is computed from the statistic Z using the cumulative

normal distribution function $D(Z) = \frac{1 + \operatorname{erf}\left(\frac{Z}{\sqrt{2}}\right)}{2}$. Since the critical region consists of equal tails, the confidence level is obtained by writing $\alpha_r = 1 - 2 \times |D(Z) - 0.5|$.

For $\bar{R} \geq 0.7$, the statistic $Z = \frac{n_1(1 - \bar{R}_1)(n_2 - 1)}{n_2(1 - \bar{R}_2)(n_1 - 1)}$ is computed and compared with

the Fisher critical values for the distribution with $n_1 - 1$ and $n_2 - 1$ degrees of freedom. The Fisher critical values can be looked up in tables or found using its cumulative distribution function as follows:

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

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

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

Since the critical region consists of equal tails, the confidence level can be obtained by writing $\alpha_r = 1 - 2 \times |D(Z) - 0.5|$.

[0061] The second part of the parametric test for repeatability of the distribution of the orientation field is an equal mean directions test with a confidence level α_r . In this test, the test statistic

$$F_{1, N-2} = \frac{\left(1 + \frac{3}{8K}\right)(N-2)(n_1 \bar{R}_1 + n_2 \bar{R}_2 - N\bar{R})}{(N - n_1 \bar{R}_1 - n_2 \bar{R}_2)} \text{ is computed and compared with the}$$

Fisher critical values for the distribution with 1 and $N-2$ degrees of freedom. For this particular test, the Fisher critical values are provided by a table lookup operation for the following confidence level $\alpha \in \{10\%, 5\%, 2.5\%, 1\%\}$. If the data are not normally distributed (c.f. Chi-Square test for normality), or if the confidence level for the equal concentration test is $\alpha_r < 0.05$, then the confidence level for the repeatability test is given a value of 0. Otherwise, the confidence level of the mean directions test is then the confidence level α_r of the repeatability test.

[0062] The equal concentrations part or the mean equal directions part of the second repeatability test can fail for very narrow distributions of angles and high values of the estimated concentrations. This likely happens because of the value of the concentrations estimates becoming less reliable when the distributions are narrow, or the test becoming more sensitive with $\bar{R}_1$ and $\bar{R}_2$ being very close to 1 (for both the concentration and the mean orientation test). Consequently, if desired, the second repeatability test can be bypassed when both the estimates of $\bar{\kappa}$ are above the threshold of 20 and the difference of mean directions is less than 15° . More particularly,

233

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

$\alpha = 1$

else

execute the second repeatability test

endif

Once the second repeatability test is executed for all the $C_9^2 = 36$ possible pairs of zones, the score for the second repeatability test is computed as follows

$$repeatability_2 = \frac{\sum_{i \in [1,9]} \sum_{j \in [1,9] \atop i \neq j} a_{z_i, z_j}}{C_9^2}$$

Details regarding the first and second parts of the second repeatability test are set forth in as described in Mardia, "Statistics of Directional Data", Academic Press, New York, 1972, pp. 161-162 (equal concentration) and pp. 152-155 (equal means direction), which is herein incorporated by reference in its entirety.

[0063] The scores of the first and second repeatability tests are then added to provide a total repeatability score (e.g., $repeatability = repeatability_1 + repeatability_2$).

Finally, the normality, nonuniformity and repeatability tests at a given scale (given size of the orientation kernel) are grouped together. For example, they are grouped together as follows:

$$orientation_stationarity = \frac{1}{4} normality + \frac{1}{4} nonuniformity + \frac{1}{2} repeatability$$

Preferably, the size of the kernel is set to $\frac{1}{2}$ of the smallest image dimension. Note that the orientation stationarity scores are expressed in percentages.

[0064] FIG. 7 illustrates the operations of block 111B (FIG. 1(B)) that characterize the scale and affinity stationarity of the training image of block 109. The scale and affinity stationarity of the training image is rotation-dependent.

Therefore, the operations on the training image (labeled block 701) begin by computing the orientation field of the training image (block 703). Preferably, the orientation field of the training image is computed using the same technique and parameters as described above with respect to blocks 407 to 409 of FIG. 4. The orientation field is computed for all the categories of the training image. The textural attributes used for the computation of the scale and affinity statistics are features extracted from Gray Level Co-Occurrence Matrices (explained below with respect to blocks 709 and 719). This methodology requires measuring the difference in gray level intensity between neighboring pairs of pixels at given displacements. Each pixel of the image is compared with pixels from the same image but taken at a number of different displacements (In the preferred embodiment, 28 different displacements). For a particular displacement, the displaced pixels are grouped into a displacement image. Therefore, in the preferred embodiment, we have 28 displacement images. In blocks 705 and 707, the training image is sampled using the orientation field as a guide to extract a number of different displacement images (in the illustrative embodiment, 28 different displacement images). In the preferred embodiment as described below, the orientation information is integrated into the displacement images utilizing rotation-dependent sampling. These displacement images are used to compute Gray Level Co-Occurrence Matrices of small sliding windows scanned over the image (block 709). Textural feature vectors are derived from these Gray Level Co-Occurrence Matrices (block 711).

339

[0065] In a parallel path, a region (or zone) of the training image is selected (block 713). This region or zone, which is referred to below as a reference pattern, has the same dimensions as the sliding windows used in block 709. Similar to the operations of blocks 705 - 711, the reference pattern is sampled using the orientation field as a guide (block 715). However, when sampling the small image of the reference pattern, not only is the image corrected for orientation but different affinity transformations are imposed on the circular neighborhood system used for sampling. By modifying the affinity factors, different scales and elongations along the X and Y axes are obtained, thereby deriving displacement images at different affinities (block 717). Thus, in the preferred embodiment, instead of having just 28 displacement images and 1 vector of textural attributes (as is the case for the training image), the operations generate from the reference pattern $28 \times N$ displacement images and N vectors of textural attributes for the reference pattern, where N is a number of (X, Y) affinity couples. For each choice of the X and Y affinity, a rotation-dependent sampling of the reference pattern is performed. In the illustrative embodiment shown in FIG. 10, N is chosen to be equal to 25 with 5 possible values for the affinity along the X axis (e.g., x0.5, x0.667, x1, x1.5, x2) and 5 possible values for the affinity along the Y axis (e.g., x0.5, x0.667, x1, x1.5, x2). The displacement images generated in block 719 are used to compute Gray Level Co-Occurrence Matrices of small sliding windows scanned over the image (block 719). Textural feature vectors are derived from these Gray Level Co-Occurrence Matrices (block 721). The textural feature vectors generated in block 721 are derived from different scale transformations (which are sometimes referred to herein as "affinity dilations") of the same reference pattern. In block 723, the operations measure the similarity (e.g., a Euclidian distance) between the texture feature vectors generated in block 721 and the texture feature vectors generated in block 711. In block 725, for a given zone (sliding window) of the training image, the operations select the affinity transform that yields a dilated version of the reference pattern that minimizes the similarity measure calculated in block 723. These results can be interpreted as an affinity map of the training image under the assumption that one unique reference pattern is reproduced over the whole image at different scales.

240

In block 727, stationarity statistics and a score are computed using the affinity transforms identified in block 725. In block 729, the affinity maps (also referred to herein as similarity maps) can be displayed. The statistics and score computed in block 727 and the affinity map displayed in block 729 relate to the particular reference pattern selected in block 713.

[0066] In block 731, it is determined whether the operations should revert back to block 713. This decision can be made in accordance with user input or automatically by a sliding window. If the decision in block 731 is yes, another reference pattern is selected in block 713 and stationarity statistics and a score related thereto are generated in blocks 715-729 as described above. If the decision in block 731 is no, an average of the scores generated in block 727 over a number of reference patterns can be computed in block 733, and/or a composite affinity map derived from the affinity maps generated in block 725 over a number of reference patterns can be displayed in block 735, and the processing ends.

[0067] In the preferred embodiment, the derivation of the displacement images in blocks 705/707 and blocks 715/717 employ the principal of the N -th order circular neighborhood system, which is explained in detail in Deng et al., "Gaussian MRF Rotation-Invariant Features for Image Classification," IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 26, No. 7, July 2004. More particularly, this isotropic circular neighborhood system is used for the sampling of neighbor pixels relative to a reference central pixel. The sampled neighbors are all situated on concentric circles of pixel radius $r=1$, $r=2$, $r=3$, ... $r=N$ where N is the order of the neighborhood. A bilinear interpolation may be used to interpolate the intensity values of samples that do not fall exactly on the center of the pixels. FIG. 8 illustrates the circular 4-th order neighborhood system used in the preferred embodiment, with respectively 4, 6, 8 and 10 samples taken on the semi-circles of radius $r_1=1$, $r_2=2$, $r_3=3$ and $r_4=4$. These samples sum to provide $4 + 6 + 8 + 10 = 28$ displacement points as follows:

241

$$\begin{aligned} \forall k \in [1,4], \begin{cases} \theta_k = \frac{(k-1)\pi}{4} \\ u_k = r_1 \cos(\theta_k) \\ v_k = r_1 \sin(\theta_k) \end{cases} & \quad \forall k \in [5,10], \begin{cases} \theta_k = \frac{(k-5)\pi}{6} \\ u_k = r_2 \cos(\theta_k) \\ v_k = r_2 \sin(\theta_k) \end{cases} \\ \\ \forall k \in [11,18], \begin{cases} \theta_k = \frac{(k-11)\pi}{8} \\ u_k = r_3 \cos(\theta_k) \\ v_k = r_3 \sin(\theta_k) \end{cases} & \quad \forall k \in [19,28], \begin{cases} \theta_k = \frac{(k-19)\pi}{10} \\ u_k = r_4 \cos(\theta_k) \\ v_k = r_4 \sin(\theta_k) \end{cases} \end{aligned}$$

Such a sampling has the advantage of providing a complete coverage of each pixel in the circular neighborhood without falling into the trap of sampling several times the same pixel or pair pixels.

[0068] For the operations of blocks 705 and 707 that generate the displacement images for the training image, the circular neighborhood system is adapted for rotation-dependent sampling. More particularly, let u and v be the coordinates column vectors of the sampling points in the X-Y plane for a rotation angle of 0, and let u' and v' be their result after a rotation of an angle φ in the rotation-dependent neighborhood sampling. The rotation by an angle φ of the neighborhood sampling coordinates is then:

$$\begin{bmatrix} u' \\ v' \end{bmatrix} = \begin{bmatrix} \cos(\varphi) & \sin(\varphi) \\ -\sin(\varphi) & \cos(\varphi) \end{bmatrix} \begin{bmatrix} u \\ v \end{bmatrix}$$

An exemplary embodiment of such rotation-dependent sampling using a 4-th order circular neighborhood sampling system is illustrated in FIG. 9, with a rotation $\varphi = -60$ degrees. The embodiment of FIG. 9 also adds scale-dependent sampling as described below, which can be ignored for the purposes of blocks 705 and 707. Like the un-rotated neighborhood sampling, a bilinear interpolation may be used to interpolate the intensity values of samples that do not fall exactly on the center of the pixels. Since the image representation on screen uses the indirect Cartesian coordinates system where the Y-axis is inverted and oriented

242

"downwards" whereas the X-axis is still oriented "rightwards", a rotation by an angle of $-\phi$ is applied to the circular neighborhood sampling coordinates. The rotation parameters of the neighborhood sampling system described above are derived from the orientation field vectors computed in block 703. More particularly, for each pixel of the training image or each pixel of the reference pattern, there is one value of the direction ϕ of the orientation vector, yielding the parameter ϕ of the rotation of the neighborhood sampling system. In the preferred embodiment, the rotated circular neighborhood sampling produces 28 displaced pixels for each pixel of the training image. In this manner, the rotation-dependent sampling yields 28 displacement images of the training image for subsequent analysis in block 711.

[0069] For the operations of blocks 715 and 717 that generate the displacement images for a particular reference pattern, the circular neighborhood system is adapted for rotation-and-scale-dependent sampling. More particularly, an affinity transform of the n-th order neighborhood sampling system is used in order to capture textural features at a given local X and Y scale and a given local orientation. This approach is the reverse of the stochastic generation of images through multipoint geostatistics. Indeed, as explained in Caers, "Geostatistical history matching under training-image based geological model constraints," SPE Journal, No. 74716, 2003, pp. 218-226, the local scale (affinity) and orientation information can be used to control the realization of a stochastic process and enables the repetition of a pattern at varying scales and orientations. The affinity factors a_x and a_y describe the scale transformation (dilatation) of the reference pattern along the X-axis and the Y-axis, respectively. In the illustrative embodiment shown in FIG. 10, there are 5 possible values for the affinity factor a_x (e.g., x0.5, x0.667, x1, x1.5, x2) and 5 possible values for the affinity factor a_y (e.g., x0.5, x0.667, x1, x1.5, x2), thereby provide a total of 25 different affinity factor pairs (or couples). When the aspect ratio a_y/a_x is not 1, then that pattern is elongated either along the X-axis or the Y-axis. The total affinity and rotation transformation of the circular neighborhood sampling coordinates can be written as follows:

$$\begin{bmatrix} u^{n^T} \\ v^{n^T} \end{bmatrix} = \begin{bmatrix} \cos(\varphi) & \sin(\varphi) \\ -\sin(\varphi) & \cos(\varphi) \end{bmatrix} \begin{bmatrix} a_x & 0 \\ 0 & a_y \end{bmatrix} \begin{bmatrix} u^T \\ v^T \end{bmatrix}$$

An illustration of a rotated and scaled 4-th order circular neighborhood sampling system is given in Figure 9 with a rotation $\varphi = -60$ degrees and the affinity factor couple $(a_x, a_y) = (0.5, 1)$. The affinity factor a_x of 0.5 indicates that the neighborhood sampling "zooms" along the X-axis when sampling the pattern. It is equivalent to dilating the reference pattern by a factor of 2 along the X-axis. The rotation parameters of the neighborhood sampling system described above are derived from the orientation field vectors computed in block 703. More particularly, for each pixel of the training image or each pixel of the reference pattern, there is one value of the direction φ of the orientation vector, yielding the parameter φ of the rotation of the neighborhood sampling system. The affinity parameters (a_x, a_y) are constant on all the image. However, for each set of those affinity parameters, a new set of displacement images are computed for subsequent analysis in block 721. In the preferred embodiment, the rotation-and-scale-dependent circular neighborhood sampling produces 25 sets of 28 displaced pixels for each pixel of the reference pattern, one set for each combination of X and Y affinity factors. In this manner, the rotation-and-scale-dependent sampling yields 25 sets of 28 displacement images of the reference pattern for subsequent analysis in block 721.

[0070] As described above, the operations of blocks 709 and 711 derive textural features (referred to below as "textural attributes" or "elements") from gray level co-occurrence matrices computed on the displacement images of the training image. In the preferred embodiment, the gray level co-occurrence matrices are computed as follows. First, the training image and the displacement images are quantized into G gray levels (for instance $G = 32$). Note that even when performing a multi-resolution analysis of black and white patterns, more than 2 gray levels are used since during the circular neighborhood sampling with scale and orientation transformations, most samples do not fall onto centers of pixels and are interpolated. In addition, if there are more than 2 but less than G categories in the training image, such gray level quantization allows the

operations to maintain a distinction between each category. The quantized images are then processed to compute a set of co-occurrence matrices. Each co-occurrence matrix, which can be denoted $C_d(k, l)$, estimates the probability for gray levels k and l to occur on the quantized image $I(x, y)$ at a displacement of d . This probability is measured by counting the number of pairs (x, y) and (x', y') where $I(x, y) = k$, $I(x', y') = l$ and $(x' - x, y' - y) = d$, and then dividing that number of pairs by the total number of neighboring pixels in the image. The set of co-occurrence matrices is generated by comparing each one of the quantized displacement images with the quantized training image. In the preferred embodiment, 28 co-occurrence matrices $C_d(k, l)$ are obtained. For a given displacement d , or for a given couple (training image, displacement image), each element of the co-occurrence matrix follows the formula below:

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

As shown in FIG. 11, each co-occurrence matrix is not computed on the whole training image, but on small sliding windows extracted from the image and regularly sampled. FIG. 11 illustrates the generation of co-occurrence matrices (and texture feature vectors derived therefrom). In FIG. 11, the three regions a, b and c illustrate possible locations of the sliding window. In the preferred embodiment, the locations of the sliding window are regularly sampled over the entire training image. For each one of regions a, b, c of FIG. 11, there are 28 displacement images that are interpolated, and 28 subsequent co-occurrence matrices and co-occurrence matrix statistics that are computed. Note that if the size of the sliding window is increased, more textural features are captured; yet the resolution of the affinity maps derived therefrom in block 725 decreases.

245

[0071] After the set of co-occurrence matrices have been computed, six textural features are computed from each co-occurrence matrix using the following formulas, (where $p(k,l)$ is an element of a given co-occurrence matrix):

i) Energy (angular second moment): $\sum_{k=0}^{G-1} \sum_{l=0}^{G-1} [p(k,l)]^2$;

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

iii) Dissimilarity (absolute value): $\sum_{k=0}^{G-1} \sum_{l=0}^{G-1} |k-l| p(k,l)$;

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

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

vi) Maximum probability: $\max_{k,l} p(k,l)$.

More specific details regarding these descriptors can be found in Haralick et al., "Texture Features for Image Classification," IEEE Transactions on Systems Man and Cybernetics, SMC-3, No. 6, 1973, pp. 610-621, and Materka et al., "Texture Analysis Methods – A Review," Technical University of Lodz, Institute of Electronics, COST B11 report, Brussels, 1998, herein incorporated by reference in their entireties. In this manner, a vector of 6 elements characterizes each co-occurrence matrix, which reduces the dimensionality of the textural measures. In the preferred embodiment, the 6 textural features for each one of the 28 co-occurrence matrices are grouped together to generated a vector of 168 elements that are associated with the training image.

[0072] In the preferred embodiment, similar operations as those described above with respect to blocks 709 and 711 are performed to derive textural features from gray level co-occurrence matrices computed on the displacement

246

images of the reference pattern in blocks 719 and 721. In such operations, a set of co-occurrence matrices (preferably 28) are computed for each designated affinity factor couple (e.g., for each one the 25 affinity factor couples). Each co-occurrence matrix is computed over the entire reference pattern. The 6 textural features are then generated for each co-occurrence matrix. In the preferred embodiment, 25 vectors of textural features (with each vector containing 168 elements) are generated. The 25 vectors correspond to the 25 affinity factor couples described above with respect to FIG. 10.

[0073] As described above, the operations of block 723 measure the similarity (e.g., a Euclidian distance) between the texture feature vectors generated in block 721 and the texture feature vectors generated in block 711. In the preferred embodiment, this is accomplished by generating, for each region r of the training image, the dilation a (out of 25 possible dilations aff) of the reference pattern that minimizes the Euclidian distance between the textural features vectors $V_{T,r}$ and $V_{RP,aff}$, which is represented mathematically as follows:

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

The dilation $a(r)$ is computed for each region r as indicated by the thin-lined arrows that link feature vector pairs in FIG. 11. FIG. 11 illustrates the comparison between the texture feature vectors for three different regions a, b, c of the training image and different affinity transformations of the reference pattern, denoted (x_1, y_1) , (x_2, y_2) , $(x_3, y_3) \dots (x_N, y_N)$.

[0074] The minimum Euclidian distance between feature vectors yields an affinity map showing the best affinity factors for the regions of the training image. FIG. 11 illustrates an exemplary affinity map showing the best affinity parameters (x_a, y_a) , (x_b, y_b) , (x_c, y_c) for regions a, b, c, respectively. This affinity map can be displayed in block 729 as described above.

247

[0075] FIGS. 12(B) and 12(C) illustrate another form of the affinity map wherein separate 2D images are provided for the affinity factor couples. Each 2D image describes the distance between the feature vectors for corresponding parts in the training image and the reference pattern. In the affinity map of FIG. 12(B), the pixels of each 2D image are gray-scale with the distances represented by the pixels quantized into a gray-scale range of values. In the affinity map of FIG. 12(C), the pixels of each 2D image are binary with the distances represented by the pixels assigned to a binary range of values. The closest distances are assigned to one binary value (i.e., black), while the other distances are assigned to the other binary value (i.e., white). In the example of FIGS. 12(A) - 12(C), the image of FIG. 12(A) is obtained by copying/pasting a classical training image (in the upper left corner) at various affinity transformations on the rest of the image: in the upper left corner, the pattern has an affinity transformation ($a_x=1$, $a_y=1$); in the upper right corner, the pattern is reproduced twice at an affinity transformation ($a_x=1$, $a_y=0.5$); in the middle left part of the image, the pattern is reproduced twice at an affinity transformation ($a_x=0.5$, $a_y=1$); in the middle right part of the image, the pattern is reproduced 4 times at an affinity transformation ($a_x=0.5$, $a_y=0.5$); in the lower part of the image, the pattern has an affinity transformation ($a_x=2$, $a_y=1$). The entire image of FIG. 12(A) is the training image. The highlighted rectangle in the upper left corner of the image of FIG. 12(A) is selected as the reference pattern. The affinity map of FIG. 12(B) shows the gray-scale distance between textural feature vectors extracted from the training image and textural feature vectors of the reference pattern for 9 different affinity factor couples. The affinity map of FIG. 12(C) shows the binary distance (i.e., closest distances in black) between textural feature vectors extracted from the training image and textural feature vectors of the reference pattern for 9 different affinity factor couples. The correlation between the visible affinity of the training image and the results are very good as the methodology detects an affinity ($a_x=2$, $a_y=1$) for most of the pixels in the lower part of the training image, an affinity ($a_x=0.5$, $a_y=1$) for most of the pixels in the middle left part of the training image, an affinity ($a_x=0.5$, $a_y=0.5$) for most of the pixels in the middle right part of the training image, and an affinity ($a_x=1$, $a_y=0.5$) for most of

the pixels in the upper right corner of the training image. The algorithm also detects an affinity ($a_x=1$, $a_y=1$) at two locations on the training image: as expected, in the upper left corner of the training image that was also used as the reference pattern, and towards the lower part of the training image. This artifact at affinity ($a_x=1$, $a_y=1$) is due to edge discontinuity in the 2D image that is interpreted as a scale change.

[0076] In the preferred embodiment, the operations of block 727 utilize the principles of the affinity maps as described above to generate scale stationarity statistics. Scale stationarity, relative to a reference pattern, can be measured by how many different scales (and aspect ratios) are covered by that image, or how the image spreads in a scale-space when an assumption is made that the image is derived from a repetition of a unique pattern at different scales and orientations. More particularly, scale stationarity can be defined as the departure from a single clustered value of ($X \times 1$, $Y \times 1$) on the affinity map; hence any variation along the X or Y axis of the affinity map indicates a non-stationary image. In the preferred embodiment, scale stationarity of the image is measured by calculating the spread of the cloud of points $p_1, p_2, \dots, p_n$ defined by the best matches between the image and the dilated patterns. The measure of the spread can then be simply computed as a measure of spread of points in a 2-dimensional space as shown in FIG. 13. These best-match points are located in a scale-space where the X-axis corresponds to the possible dilatation along the X-axis, and the Y-axis to the possible dilatations along the Y-axis. Each of those points, which can represent a different small zone on the image, describes by its location in that scale-space, the x and y dilation factors. The scale-space is not continuous but discrete, since only a small number of dilations of the reference pattern are computed. The dilation factors are mapped into the scale-space through a bijection (i.e., a one-to-one mapping). In the preferred embodiment, the x-dilation factors are $1/2$, $2/3$, 1 , $3/2$ and 2 and correspond to abscises of -1 , $-1/2$, 0 , $1/2$ and 1 . Such a scale space is represented in FIG. 13. In this example, the scale-space representation of the spread of a cloud of points is symbolized by an ellipse. The first and second principal component directions are shown. The two principal components of the points $p_1, p_2, \dots, p_n$ are obtained

249

by the singular value decomposition (SVD) $\begin{bmatrix} x_i \\ y_i \end{bmatrix}_{i \in [1,n]} = U \times S \times V^T$. The first

principal component gives the direction of the strongest variation of the points and the second principal component is orthogonal to the first one and gives the directions of the weakest variation of the points. The ratio s_2/s_1 of the two singular values s_1 and s_2 (which can be retrieved from the diagonal of the matrix S) gives the importance of variation of the points $p_1, p_2, \dots, p_n$ along the direction of the second principal direction. Let $u = (u_x, u_y)$ be the unitary vector defining the direction of the first principal component and let $v = (v_x, v_y)$ be the unitary vector defining the direction of the second principal component (u and v are orthogonal). The unitary vectors u and v can be obtained by normalizing the first and second column of the matrix V . The coordinates of $p_1, p_2, \dots, p_n$ in the u, v coordinates

system can be obtained from $\begin{bmatrix} u_i \\ v_i \end{bmatrix}_{i \in [1,n]} = U \times \begin{bmatrix} x_i \\ y_i \end{bmatrix}_{i \in [1,n]}$. The "spread" of the cloud of

points is defined as depending both on the variance along the first principal direction and the effect of the variance along the second, orthogonal, principal direction. The variability along the first principal direction is computed as follows:

$\text{stdev}(u_i)_{i \in [1,n]} = \sqrt{\frac{1}{n-1} \sum_{j=1}^n (u_j - \bar{u})^2}$, where $\bar{u} = \frac{1}{n} \sum_{i=1}^n u_i$. The total spread of the cloud

of points $p_1, p_2, \dots, p_n$ is defined as follows: $\text{spread} = \min \left\{ 1, \text{stdev}(u_i)_{i \in [1,n]} \times \left(1 + s_2/s_1 \right) \right\}$.

This formula has been conceived in order to give a stronger spread when the cloud of points has an elliptical or circular shape than when the spread is only with a constant Y/X ratio. Moreover, it is also constrained between the values of 0 (all the points are concentrated in the middle point (0, 0), i.e. all the scales are $\times 1, \times 1$) and 1. The scale stationarity score is simply $1 - \text{spread}$ (i.e.,

$\text{scale_stationarity} = 1 - \text{spread}$) and is expressed as a percentage. In the preferred embodiment, a fully automated scale stationarity score computation is employed in block 727 that calculates the minimum value of 9 scale stationarity scores computed with reference patterns located at the top right, top middle, top left, middle right, center, middle left, bottom right, bottom middle and bottom left

parts of the training, which is similar to the computation of the orientation stationarity score as described above. These operations can be represented mathematically as $scale_stationarity = \min_{k=1}^9 (scale_stationarity_k)$.

[0077] The operations of block 111C (FIG. 1(B)) that characterize the category distribution stationarity of the training image of block 109 verify that the distribution of categories does not change considerably from one region of the image to the other. In the preferred embodiment, the training image is subdivided into zones in a manner similar to that described above with respect to FIGS. 6(A) - 6(I) in generating the orientation stationarity statistics. A category distribution histogram H_k is computed on each zone k out of the 9 zones of the preferred embodiment. The category distribution histograms all contain G bins, where G is the number of categories. The similarity of two gray scale histograms H_k and H_l is measured using the Euclidian distance between vectors H_k and H_l :

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

[0078] The category distribution stationarity score for all the zones is computed as follows:

$$colorclass_stationarity = 1 - \min \left(1, \max_{k,l} \left(\sqrt{\sum_{c=1}^G [H_k(c) - H_l(c)]^2} \right) \right).$$

[0079] In block 113, the stationarity scores generated in block 111 are analyzed to determine if the training image satisfies a set of predetermined constraints which dictate whether or not the training image should be used in subsequent multi-point geostatistical analysis. In the preferred embodiment, the orientation stationarity score (111A), the scale stationarity score (block 111B), and the category distribution stationarity score (111C) are plotted on a three dimensional graph whose axes correspond to the three scores as illustrated in FIG. 14. A set of surfaces are defined that represent one or more regions in the three-dimensional space delimiting "good" training images. If the three scores for the particular training image fall within the one or more regions delimiting "good" training images, the stationarity criterion of block 113 is satisfied; otherwise, the

251
stationarity criterion of block 113 fails.

[0080] In the event that the stationarity criterion of block 113 is satisfied, the training image can be exported as an image grid for multipoint geostatistical analysis (block 119). Examples of such multipoint geostatistical analysis include a computer-based implementation of the SNESIM algorithm and/or a computer-based implementation of the SIMPAT algorithm.

[0081] In the SNESIM (Single Normal Equation SIMulator) method, the conditional probability density function of all categories at one point is computed utilizing knowledge of the value at a small number of nearby points and statistics provided by a "training image". SNESIM works with discrete values only (i.e. a finite and usually-small number of categories, such as for example five different rock types). Assume there are two categories to be simulated: A (intra-channel) and B (channel). The training image contains a complete representation (i.e. an example) of a spatial distribution of A and B. Assume further that the category present at 4 points (u_1, u_2, u_3, u_4), which could represent wells, is known. Conceptually, the SNESIM method computes the probability of finding categories A or B at a fifth point (u_5) by consulting the training image for all occurrences of the "pattern" (u_1, u_2, u_3, u_4) (that is all occurrences of 4 points with the same relative locations to one another and the same categories values in the training image) as shown in FIG. 15. If 5 such occurrences (these are called replicates) are found, and 4 out of 5 replicates show categories B at the relative position of the unknown point (u_5), then the method concludes that the probability of B at the unknown point is 80% (while that of A is 20%). Furthermore, the method can assign a category to the unknown point by randomly drawing a value from a distribution with 80% probability of B and 20% probability of A. In practice, the SNESIM method starts with a blank volume to be modeled, or one that contains only a few data points to be honored, and first decides on a random path for visiting each of the blank pixels once and only once. In the first pixel, the method calls for searching for nearby known points within a search ellipsoid. If one or more known (or already assigned) pixels are found, it proceeds as described above to find the probability of finding categories A or B at the unknown point. Armed with the probabilities for each category at the unknown point, the method

252

randomly draws a value (weighted by the known probabilities) and assigns it to the unknown point. The process repeats at the next pixel in the initially-assigned random path until all pixels are assigned.

[0082] Such methodology was well known in the early 1990's (before it was known as "SNESIM"). One of its problems, however, was that it was extremely computationally intensive to consult the training image multiple times. In 2000, a technique was discovered to store the information contained in the training image in a special tree-like structure that reduced computations enormously. With this improvement, the methodology was commonly referred to as the SNESIM method. Coupled with the steadily increasing power of digital computers, it brought the image-consultation problem down to reasonable (though still significant) processing times.

[0083] The core SNESIM methodology has several variations and additions that make be used to make it more powerful and useful. One improvement adds the ability to process in successive stages of increasing resolution, which improves lateral continuity of features. The number of refinements is called multiplicity. Another improvement provides the ability to use soft probabilities (possibly derived from seismic data) to further control the modeling. Through further additions, the SNESIM method can handle scale transformations by simply scaling the distances to the known points $((u_1, u_2, u_3, u_4)$ in the example above) according to user-provided location-dependent scaling information. Similarly it can incorporate information on the rotation of geologic features (such as channel directions) by rotating the set of points according to the local value of a user-provided rotation field.

253

[0084] In the SIMPAT (SIMulation with PATterns) method, the probability of occurrence of all combinations of values within a small set of contiguous points (such as a rectangular matrix) are computed. Unlike the SNESIM method, the SIMPAT method can work with either discrete (category) values, or continuous numerical values. More particularly, the SIMPAT method estimates such probabilities in the training image by counting the occurrences of these patterns by means of a moving rectangular template that scans the entire image. For example, if applied to a binary 2-dimensional image with a template of 2x2 pixels, the method assigns a probability of occurrence to every possible outcome of the 2x2 pixel template (namely 24 or 16 possible outcomes). The result is a probability distribution whose domain consists of 24 pixel combinations as shown in FIG. 16(A). In practice, larger templates (of up to about 8x8 pixels) are used leading to a very large number of possible combinations, though many may have an occurrence or probability of zero, if they are absent in the training image. Simulation is achieved by drawing at random from the distribution to progressively fill an initially empty image. Care must be taken to honor pixels already filled, or pixels that represent hard conditioning data. This can be achieved by drawing from a subset of the original distribution of pixel groups, namely the subsets of those pixel groups that honor the preexisting data.

[0085] The need to match preexisting points may lead to lengthy computation times with larger patterns, because many points need to be matched simultaneously along the borders of larger patterns. This has led to the use of a somewhat more refined method called "feature-based" geostatistics, which relies on a template that contains an inner "feature" and an outer "skin" as shown in FIG. 16(B). In practice, the feature is generally larger than 2x2 pixels, but the skin is typically one pixel wide. This partition facilitates template classification. By scanning the image, the method obtains a collection of features and their probabilities of occurrence. A given feature (2x2 pixels in this example) may occur several times, but each time with a different skin. Therefore, each feature has a probability, but many possible skins, each of which in turn has its probability (relative to the feature). When a feature needs to be assigned next to an existing one, it is drawn from all features with a matching skin, weighted by the

264

probability of each possible skin in the existing feature. Thus the skin constrains the probability of occurrence of features in its immediate neighborhood; and allows for matching of neighboring features.

[0086] The SIMPAT method can be extended in ways that are somewhat similar to the extensions of the SNESIM method. Namely, by performing the simulation in stages ranging from a coarse grid (for example a grid that only uses every fifth pixel in every direction) to a finer grid, and using the results each previous (coarser) stage as values to be honored in the next (finer) stage, the SIMPAT method greatly improves its ability to honor continuity of long features (such as channels). Also, the patterns can be scaled and rotated to honor user-provided local scaling and rotation information. In general, the SIMPAT method achieves better results than the SNESIM method (in that it honors the statistics of the original training image more closely) but is also computationally slower.

[0087] In the event that the stationarity criterion of block 113 fails, the non-stationary training image can be exported as an image grid for multi-point geostatistical analysis (block 127A). Similarly, the orientation grid and affinity maps derived as part of the computation of the stationarity statistics herein can be exported as constraint grids for multipoint geostatistical analysis that accepts non-stationary training images.

[0088] The computer-based methodology described above can readily be extended to three-dimensional training images. More particularly, the workflow of FIG. 1B would be modified as follows. First, blocks 101-105 are adapted to store and retrieve 3D images. Second, block 107 is adapted to use 3D versions of the 2D image processing operations described above in order to preprocess 3D images and create valid 3D training images. Finally, block 111 is adapted to use 3D versions of the 2D operations described above for generating the stationarity statistics. More particularly, instead of subdividing the 2D training image into 9 overlapping rectangles (FIGS. 6(A) - 6(I)), the 3D training image can be subdivided into 27 overlapping cubes. A 3D version of the operations that extract the orientation field of the training image is used. In this case, the first principal components of the 3D orientation vectors are perpendicular to gradient surfaces.

255

These 3D orientation vectors are spherical data on which stationarity statistics are extracted. 3D versions of the operations described above for assessing the stationarity of the orientation field are described in Mardia, "Statistics of Directional Data," Academic Press, New York, 1972, and Rock, "Lecture Notes in Earth Sciences 18 – Numerical Geology," Springer Verlag, 1988, incorporated by reference herein in their entireties. 3D versions of the operations described above for accessing scale stationarity would also be used. In such operations, the gray level co-occurrence matrices used therein require a spherical neighborhood system instead of a circular one. The scale stationarity statistics themselves would be done on 3D scale-space affinity maps using the 3D version of the SVD and standard deviation. The category stationarity statistics can be easily performed on category distributions from the 27 overlapping cubes of the 3D image (instead of 9 overlapping rectangles of the 2D image). The stationarity criteria of block 113 would be similarly applied to keep or discard 3D training images. Similarly, the training image grids, as well as the scale and orientation constraint grids, can be exported as 3D grids (instead of 2D grids).

[0089] The computer-based methodology of the present invention can also readily be extended to work with training images that have continuous values instead of a small number of categories. Therefore, the methodology is suitable for multipoint geostatistical methods that accept training image grids containing property values (instead of categories).

[0090] The computer-based methodologies of the present invention have been tested on a library of thirty-eight training images and have been shown to accurately identify whether or not the stationarity of a candidate training image makes it suitable for MPGS realizations. By consequence, geologists save time and avoid running unnecessary MPGS realizations using unsuitable training images. Moreover, the computer-based methodologies of the present invention are computationally efficient, and typically can be executed on a conventional laptop computer in only a few seconds, whereas one needs to wait much longer for the results of one realization of MPGS algorithms. Finally, the stationarity statistics results output by the computer-based methodology of the present invention have been thoroughly verified, and have been found to be similar to the

25b

outcome of a human interpretation based on a visual inspection of training images.

[0091] There have been described and illustrated herein computer-based methodologies for automatically evaluating the stationarity of training images for use in multipoint geostatistical analysis. While particular embodiments of the invention have been described, it is not intended that the invention be limited thereto, as it is intended that the invention be as broad in scope as the art will allow and that the specification be read likewise. It will therefore be appreciated by those skilled in the art that yet other modifications could be made to the provided invention without deviating from its spirit and scope as claimed.

257

WHAT IS CLAIMED IS:

1. A computer-implemented method comprising:

analyzing digital data representing an image to generate at least one statistic characterizing stationarity of the image;

deriving at least one score based upon said at least one statistic;

determining whether said at least one score satisfies a stationarity criterion; and

upon determining that said at least one score satisfies said stationarity criterion, storing or outputting said image for use as a stationary training image grid in at least one multipoint geostatistical analysis.

2. A computer-implemented method according to claim 1, wherein:

said at least one statistic comprises a plurality of statistics that characterize stationarity of an orientation field extracted from said image.

3. A computer-implemented method according to claim 2, wherein:

said orientation field is computed by deriving a gradient field through 2D convolution on said image and then extracting a principal component of the gradient field over a sliding window of fixed size using principal component analysis.

259

4. A computer-implemented method according to claim 3, wherein:

the 2D convolution employs Prewitt filters.

5. A computer-implemented method according to claim 2, wherein:

the plurality of statistics that characterize stationarity of the orientation field include at least one of the following: (i) a first set of statistics that characterize nonuniformity of the orientation field and thus provide an indication that there is one or several preferential directions in the orientation grid, (ii) a second set of statistics that characterize the normality of the distribution of directions in the orientation grid and thus provides an indication that there is a dominant direction in the orientation field, and (iii) a third set of statistics that characterize the repeatability of the orientation field, which provides an indication that the orientation field is similar across different zones of the image.

6. A computer-implemented method according to claim 5, wherein:

the plurality of statistics are computed over a plurality of overlapping zones in the image.

7. A computer-implemented method according to claim 5, further comprising:

deriving a first score based upon the first set of statistics;

deriving a second score based upon the second set of statistics;

deriving a third score based upon the third set of statistics; and

deriving a score that characterizes orientation stationarity of the image based upon the first, second and third scores.

259

8. A computer-implemented method according to claim 7, wherein:

the score that characterizes orientation stationarity of the image is computed from a weighted average of the first, second and third scores.

9. A computer-implemented method according to claim 1, wherein:

said at least one statistic comprises a plurality of statistics that characterize scale stationarity of said image.

10. A computer-implemented method according to claim 9, wherein:

the plurality of statistics that characterize scale stationarity of the image comprise distances between a first set of feature vectors and a second set of feature vectors, the first set of feature vectors derived from a first set of displacement images that are generated by subjecting the image to a plurality of rotation-dependent sampling operations, and the second set of feature vectors derived from a second set of displacement images that are generated by subjecting a reference pattern selected from the image to a plurality of rotation-and-scale-dependent sampling operations.

11. A computer-implemented method according to claim 10, wherein:

the plurality of rotation-dependent sampling operations employ circular neighborhood sampling with orientation transformations; and

the plurality of rotation-and-scale-dependent sampling operations employ circular neighborhood sampling with both scale and orientation transformations.

12. A computer-implemented method according to claim 11, wherein:

the orientation transformations are performed over a predetermined number of affinity factor pairs.

13. A computer-implemented method according to claim 10, wherein:

the first set of feature vectors are computed by calculating gray level co-occurrence matrices over the first set of displacement images; and

the second set of feature vectors are computed by calculating gray level co-occurrence matrices over the second set of displacement images.

14. A computer-implemented method according to claim 10, further comprising:

generating an affinity map that characterizes the distances between the first set of feature vectors and the second set of feature vectors over the training image.

15. A computer-implemented method according to claim 14, wherein:

the affinity map identifies regions of the image and a particular affinity factor couple associated with each given region, the particular affinity factor couple identify by minimizing distance between the feature vectors of the first set pertaining to the given region and the feature vectors of the second set pertaining to different affinity factor couples.

16. A computer-implemented method according to claim 14, wherein:

the affinity map includes sub-maps each corresponding to a different affinity factor couple, wherein a given sub-map characterizes distances between

the feature vectors of the first set and the feature vectors of the second set pertaining to the particular affinity factor couple of the given sub-map.

17. A computer-implemented method according to claim 16, wherein:

each sub-map comprises a plurality of gray scale pixels.

18. A computer-implemented method according to claim 16, wherein:

each sub-map comprises a plurality of binary pixels.

19. A computer-implemented method according to claim 14, further comprising:

displaying the affinity map.

20. A computer-implemented method according to claim 1, wherein:

said at least one statistic comprises a plurality of statistics that characterize category distribution stationarity of said image.

21. A computer-implemented method according to claim 1, further comprising:

upon determining that said at least one score does not satisfy said stationarity criterion, storing or outputting said image for use as a non-stationary training image grid in at least one multipoint geostatistical analysis.

22. A computer-implemented method according to claim 2, further comprising:

262

storing or outputting said orientation field for use in at least one multipoint geostatistical analysis.

23. A computer-implemented method according to claim 14, further comprising:

storing or outputting said affinity map for use in at least one multipoint geostatistical analysis.

24. A computer-implemented method according to claim 1, further comprising:

applying image processing operations on a candidate image to generate an image suitable for the analysis that generates at least one statistic characterizing stationarity of the image, said image processing operations reducing the number of grayscale/color levels of the candidate image while keeping geological significance of the assigned categories of the candidate image.

263

ABSTRACT OF THE DISCLOSURE

A computer-implemented method is provided that automatically characterizes and verifies stationarity of a training image for use in multipoint geostatistical analysis. The stationarity is preferably characterized by statistical measures of orientation stationarity, scale stationarity, and category distribution stationarity.

264

DECLARATION FOR PATENT APPLICATION AND POWER OF ATTORNEY

As a below named inventor, I/We hereby declare that:

My/Our residence, post office address(s) and citizenship(s) are as stated below next to my/our name(s), and

I/We believe I/We am/are the original, first and sole inventor of the subject matter which is claimed (if only one name is listed below) or an original and first inventor of at least some of the subject matter which is claimed (if plural names are listed below) and for which a patent is sought on the invention entitled

COMPUTER-BASED GENERATION AND VALIDATION OF TRAINING IMAGES FOR MULTIPOINT GEOSTATISTICAL ANALYSIS

the specification of which

- ☒ is attached hereto.
☐ was filed on
as Application Serial Number:
and was amended on (if applicable).

I/We hereby state that I/we have reviewed and understand the contents of the above identified specification, including the claims, as amended by any amendment referred to above.

I/We acknowledge the duty to disclose information which is material to the examination of this application in accordance with Title 37, Code of Federal Regulations, Section 1.56(a).

Prior Foreign Application(s)

I/We hereby claim foreign priority benefits under Title 35, United States Code, Section 119 of any foreign application(s) for patent or inventor's certificate listed below and have also identified below any foreign application(s) for patent or inventor's certificate having a filing date before that of the application on which priority is claimed:

Country	Application No.	Filed (d/m/y)	Issued (d/m/y)	Priority Claimed
				Y ☐ N ☐
				Y ☐ N ☐

Prior United States Applications

I/We hereby claim the benefit under Title 35, United States Code, Section 120 of any United States application(s) listed below and, insofar as the subject matter of each of the claims of this application is not disclosed in the prior United States application in the manner provided by the first paragraph of Title 35, United States Code, Section 112, I/We acknowledge the duty to disclose material information as defined in Title 37, Code of Federal Regulations, Section 1.56(a) which occurred between the filing date of the prior application and the national or PCT international filing date of this application:

Application Serial No.	Filing Date (d/m/y)	Status (Patented, Pending, Abandoned)

And, I/We hereby appoint, both jointly and severally, as my attorney(s) and/or agent(s) with full power of substitution and revocation, to prosecute this application and to transact all business in the Patent and Trademark Office connected herewith the following attorney(s) and agent(s), their registration numbers being listed after their names.

Dale Gaudier, 28,213; William L. Wang, 39,871; Jody Lynn DeStefania, 44,653; David P. Gordon, 29,996; Thomas A. Gallagher, 31,358; and David S. Jacobson, 39,235

I/We hereby request that all correspondence be directed to:

Customer Number 37003
Intellectual Property Law Department
Schlumberger-Doll Research
36 Old Quarry Rd., Ridgefield, CT 06877

and that all telephone calls be directed to Intellectual Property Law Department at (203) 431-5507, and all facsimile calls be directed to Intellectual Property Law Department at (203) 431-5640.

I hereby declare (if sole inventor) or each of us hereby declares (if joint inventors) that all statements made herein of my own knowledge are true and that all statements made on information and belief are believed to be true; and further that these statements were made with the knowledge that willful false statements and the like so made are punishable by fine or imprisonment, or both, under Section 1001 of Title 18 of the United States Code and that such willful false statements may jeopardize the validity of the application or any patent issuing thereon.

SOLE OR FIRST INVENTOR

Signature: _____ Date: _____

Full Name: Piotr Mirowski

Residence: 25 Indian Road, Apt. 1E, New York, New York 10034, USA

Citizenship: France

Post Office Address: 25 Indian Road, Apt. 1E, New York, New York 10034, USA

SECOND INVENTOR

Signature: _____ Date: _____

Full Name: Daniel Tetzlaff

Residence: 9538 Beverlyhill Street, Houston, Texas 77063, USA

Citizenship: U.S.A.

Post Office Address: 9538 Beverlyhill Street, Houston, Texas 77063, USA

THIRD INVENTOR

Signature: _____ Date: _____

Full Name: David McCormick

Residence: 18 Bromfield Road, Acton, Massachusetts 01720, USA

Citizenship: U.S.A.

Post Office Address: 18 Bromfield Road, Acton, Massachusetts 01720, USA

SCHLUMBERGER-DOLL RESEARCH
36 Old Quarry Road
Ridgefield, CT 06877-4108

266

FOURTH INVENTOR

Signature: _____ Date: _____

Full Name: **Nueka Williams**

Residence: **255 Massachusetts Avenue, Apt. 709, Boston, Massachusetts 02115, USA**

Citizenship: **U.S.A.**

Post Office Address: **255 Massachusetts Avenue, Apt. 709, Boston, Massachusetts 02115, USA**

FIFTH INVENTOR

Signature: _____ Date: _____

Full Name: **Claude Signer**

Residence: **265 Willow Avenue, Somerville, Massachusetts 02144, USA**


Citizenship: **France**

Post Office Address: **265 Willow Avenue, Somerville, Massachusetts 02144, USA**

SCHLUMBERGER-DOLL RESEARCH
36 Old Quarry Road
Ridgefield, CT 06877-4108


267

FIG. 1(A)



Best Available Copy

Figure 1(B)



267

Figure 2(A)



Figure 2(B)




Figure 2(C)




Figure 2(D)



Figure 2(E)



Figure 3(A)



Figure 3(B)

Y-Component of the gradient field using a Prewitt operator



Figure 3(C)

X-Component of the gradient field using a Prewitt operator




Figure 3(D)

Calculated field: based on 84x84 pixels, sampled every 10 pixels



Figure 4



272

Figure 5(A)



Figure 5(B)




Figure 6(A)




Figure 6(B)




Figure 6(C)




Figure 6(D)




Figure 6(E)




Figure 6(F)




Figure 6(G)




Figure 6(H)




Figure 6(I)






Figure 7



274

Figure 8



275

Figure 9






FIG. 10(A)**FIG. 10(B)**

2.77

FIG. 10(C)





FIG. 10(D)

279

FIG. 10(E)




FIG. 10(F)






FIG. 10(G)




281

FIG. 10(H)




282

FIG. 10(I)



283

FIG. 10(J)



284

FIG. 10(K)






FIG. 10(L)



293

FIG. 10(M)



286

FIG. 10(N)




FIG. 10(O)




FIG. 10(P)




FIG. 10(Q)






FIG. 10(R)




29

FIG. 10(S)



291

FIG. 10(T)



292

FIG. 10(U)






FIG. 10(V)




293

FIG. 10(W)



294

FIG. 10(X)



205

FIG. 10(Y)




Figure 11




Figure 12(A)




Figure 12(B)






Figure 12(C)




298

Figure 13



299

Figure 14



360
300

FIG. 15



Retrieve training replicates of d_n




FIG. 16(A)




FIG. 16(B)



302

TRADUCCION OFICIAL No. 2006-09-15-596
DE UN DOCUMENTO, ESCRITO EN INGLES

APOSTILLA

(Convención de La Haya del 5 de octubre de 1961)

1. País: Estados Unidos de América
Este documento público
2. ha sido firmado por T. Lawrence
3. actuando como Funcionario que Certifica
4. lleva el sello/estampilla de la Oficina de Patentes y Marcas de los EE.UU.

CERTIFICADO

5. en Washington, D.C.
6. el 23 de agosto de 2006
7. por el Funcionario de Autenticaciones Asistente, Departamento de Estado
de los Estados Unidos
8. No. 06031949-2
9. Sello/Estampilla
Departamento de Estado
de los Estados Unidos
10. Firma: (ilegible)
Patrick O. Hatchett

TRADUCTORA OFICIAL
C.O. 0177/88 MIN. JUSTICIA

NILDA ELVIRA DE TAMAYO

303

LOS ESTADOS UNIDOS DE AMERICA
A TODOS AQUELLOS QUE VIEREN ESTOS PRESENTES:
DEPARTAMENTO DE COMERCIO DE LOS ESTADOS UNIDOS
Oficina de Patentes y Marcas de los Estados Unidos

08 de agosto de 2006

**EL PRESENTE ES PARA CERTIFICAR QUE ANEXA SE ENCUENTRA UNA
COPIA FIEL DE LOS REGISTROS DE ESTA OFICINA DE UN DOCUMENTO
REGISTRADO EL 7 de noviembre de 2005.**

**Sello del Departamento de Comercio
Oficina de Patentes y Marcas de los
Estados Unidos**

**Por Autoridad del
Subsecretario de Comercio para
Propiedad Intelectual y
Director de la Oficina de Patentes y
Marcas de los Estados Unidos**

**(firma: ilegible)
T. LAWRENCE
Funcionario que Certifica**

TRASPASO DE PATENTE	
Versión Electrónica v1.1	
Versión Hoja Estilo v1.1	
TIPO DE PRESENTACION	NUEVO TRASPASO
NATURALEZA DEL TRASPASO	TRASPASO
DATOS DE LA PARTE QUE TRASPASA	
Nombre	Fecha de Ejecución
Piotr Mirowski	07/22/2005
Daniel Tetzlaff	08/31/2005
David McCormick	08/31/2005
Nneka Williams	08/30/2005
Claude Signer	08/31/2005
DATOS DE LA PARTE QUE RECIBE	
Nombre:	Schlumberger Technology Corporation
Dirección:	36 Old Quarry Road
Ciudad:	Ridgefield
Estado/País:	CONNECTICUT
Código Postal:	06877-4108
Total NUMEROS PROPIEDAD: 1	
Tipo de Propiedad	Número
Número de la Solicitud:	11180191
DATOS DE CORRESPONDENCIA	
Número Fax:	(617)252-4780
<i>La correspondencia será enviada vía US Mail cuando el intento por fax no sea exitoso.</i>	

305

Teléfono: 617-252-4717	
Email: JConner2@boston.oilfield.slb.com	
Nombre Corresponsal: Schlumberger-Doll Research	
Dirección Línea 1: 36 Old Quarry Road	
Dirección Línea 4: Ridgefield, CONNECTICUT 06877-4108	
NUMERO EXPEDIENTE APODERADO	60.1621 US NP
NOMBRE DEL PRESENTADOR:	James J. Conner
Total anexos: 6	
1621 US NP Assign#page1.tif	
1621 US NP Assign#page22.tif	
1621 US NP Assign#page3.tif	
1621 US NP Assign#page4.tif	
1621 US NP Assign#page5.tif	
1621 US NP Assign#page6.tif	

PATENTE

REEL: 016741 FRAME: 0753

306

TRASPASO

POR CUANTO, Yo/Nosotros, Piotr Mirowski, ciudadano de Francia, residente en 25 Indian Road, Apt. 1E, New York, New York 10034; Daniel Tetzlaff ciudadano de los Estados Unidos, residente en 9538 Beverlyhill St., Houston, Texas 77063; David McCormick, ciudadano de los Estados Unidos, residente en 18 Bromfield Road, Acton, Massachusetts 01720; Nneka Williams, ciudadano de los Estados Unidos, residente en 255 Massachusetts Avenue, Apt. 709, Boston, Massachusetts 02115; y Claude Signer ciudadano de Suiza, residente en 265 Willow Avenue, Sommerville, Massachusetts 02144 hemos inventado

GENERACION Y VALIDACION COMPUTARIZADA DE IMAGENES DE ENTRENAMIENTO PARA ANALISIS GEOESTADISTICOS DE PUNTOS MULTIPLES

según se describe y explica en una Solicitud de Patente de los EU, presentada el 13 de julio de 2005, No. Serial 11/180.191 (Expediente del Apoderado No. 60.1621 US NP).

Y POR CUANTO, SCHLUMBERGER TECHNOLOGY CORPORATION, sus sucesores y cesionarios (SOCIEDAD), una sociedad organizada, incorporada y existente bajo las leyes de Texas, y que tiene un lugar de negocios en 36 Old Quarry Road, Ridgefield, CT 06877-4108, EE.UU. desea adquirir o confirmar su adquisición de todo derecho, título e interés en esta invención, invenciones o mejoras, solicitud, y cualquier patente, tanto en los Estados Unidos y todos los países extranjeros;

AHORA, POR LO TANTO, A TODOS A QUIENES INTERESE, SEPASE, que yo/nosotros, el inventor(es), por contraprestaciones buenas, suficientes y valiosas, cedo, transfiero y traspaso a la SOCIEDAD todo derecho, título e interés en todo el mundo, en mi/nuestra invención según se describe en dicha solicitud, incluyendo el derecho de presentar solicitudes extranjeras bajo las disposiciones de una convención o tratado; una solicitud de confirmación, divisional, continuación, continuación en parte, o sustituto que pudiese presentarse sobre esta invención en cualquier parte; y cualesquiera patentes, certificados, modelos de utilidad, reexpediciones, extensiones, adiciones o confirmaciones que pudiesen otorgarse en cualquier parte para la invención, PARA TENER Y MANTENER la misma hasta el final del término o términos para el cual una patente pueda ser expedida.

Y yo/nosotros autorizamos y solicitamos a la autoridad apropiada que expida una patente relacionada a la SOCIEDAD como el cesionario del derecho, título e interés completo en la patente, para el uso y beneficio solo de la SOCIEDAD.

Y yo/nosotros acordamos y garantizamos que yo/nosotros tengo el pleno derecho a ceder todo el derecho, título e interés en esta invención libre de todas las licencias, gravámenes o embargos, y que yo/nosotros no he ejecutado y no ejecutaré ningún instrumento que entre en conflicto con este acuerdo.

Y yo/nosotros acuerdo que yo/nosotros, mi/nuestros ejecutores, administradores u otros representantes personales, haré todo lo que sea legalmente necesario (haré todos los juramentos legítimos, ejecutaré y entregaré cualquiera y todos los otros instrumentos por escrito, y cualquiera y todas las solicitudes, papeles, poderes, affidávit, cesiones, renunciaciones y otros documentos

300
309

adicionales) en opinión del asesor legal de la SOCIEDAD, para asegurar y traspasar el título a la SOCIEDAD, todo derecho, título e interés en esta invención, invenciones, o mejoras, solicitud o solicitudes, patentes, derechos, títulos, beneficios, privilegios y ventajas.

EN TESTIMONIO DE LO CUAL, firmo este día 22 de julio de 2005.

(firma: ilegible)
Piotr Mirowski

Estado de Connecticut)
Condado de Fairfield)

SEPASE, que en este día 22 de julio de 2005, Piotr Mirowski compareció personalmente ante y ejecutó este traspaso.

Ruth A. Schreiber
Notario Público - Connecticut
Mi Comisión Expira el 31 de julio de 2010

(firma: ilegible)
Ruth A. Schreiber

SELLO

PATENTE
REEL: 016741 FRAME: 0755

EN TESTIMONIO DE LO CUAL, firmo este día 31 de agosto de 2005.

(firma: ilegible)
Daniel Tetzlaff

309
309

Commonwealth de Massachusetts)
Condado de Middlesex)

SEPASE, que en este día 31 de agosto de 2005, Daniel Tetzlaff compareció personalmente ante y ejecutó este traspaso.

Carol Judith Venitt
Notario Público, Massachusetts
Mi Comisión Expira el 12 de enero de 2010

(firma: ilegible)

SELLO

PATENTE

REEL: 016741 FRAME: 0756

EN TESTIMONIO DE LÓ CUAL, firmo este día 31 de agosto de 2005.

(firma: ilegible)

David McCormick

Commonwealth de Massachusetts)
Condado de Middlesex)

SEPASE, que en este día 31 de agosto de 2005, David McCormick compareció personalmente ante y ejecutó este traspaso.

Carol Judith Venitt
Notario Público, Massachusetts
Mi Comisión Expira el 12 de enero de

(firma: ilegible)

Notario Público

SELLO

PATENTE

REEL: 016741 FRAME: 0757

4 " .

EN TESTIMONIO DE LO CUAL, firmo este día 30 de agosto de 2005.

(firma: ilegible)
Nneka Williams

Commonwealth de Massachusetts)
Condado de Middlesex)

SEPASE, que en este día 30 de agosto de 2005, Nneka Williams compareció personalmente ante y ejecutó este traspaso.

Carol Judith Venitt
Notario Público, Massachusetts
Mi Comisión Expira el 12 de enero de

(firma: ilegible)
Notario Público

SELLO

PATENTE
REEL: 016741 FRAME: 0758

EN TESTIMONIO DE LO CUAL, firmo este día 31 de agosto de 2005.

(firma: ilegible)
Claude Signer

Commonwealth de Massachusetts)
Condado de Middlesex)

SEPASE, que en este día 31 de agosto de 2005, Claude Signer compareció personalmente ante y ejecutó este traspaso.

Carol Judith Venitt
Notario Público, Massachusetts
Mi Comisión Expira el 12 de enero de

(firma: ilegible)
Notario Público

SELLO

REGISTRADO: 11/07/2005

PATENTE

REEL: 016741 FRAME: 0759

Traducido según mi mejor saber y entender, este día 15 de septiembre de 2006, en la ciudad de Bogotá, D.C., por Anita Escobar de Tamayo, Traductora Oficial, Res. 2177 de 1989, Ministerio de Justicia, República de Colombia.

TRADUCTORA OFICIAL
RES. 2177/89 MIN. JUSTICIA
Anita Escobar de Tamayo
ANITA ESCOBAR DE TAMAYO

312.

APOSTILLE

(Convention de La Haye du 5 octobre 1961)

1. Country: United States of America

This public document

2. has been signed by T. Lawrence

3. acting in the capacity of Certifying Officer

4. bears the seal/stamp of U.S. Patent and Trademark Office

Certified

5. at Washington, D.C.

6. the twenty-third of August, 2006

7. by *Assistant Authentication Officer, United States Department of State*

8. No. 06031949-2

9. Seal/Stamp:

10. Signature:



Patrick O. Hatchett

Columbia

314
313

A 1501459

THE UNITED STATES OF AMERICA

TO ALL TO WHOM THESE PRESENTS SHALL COME:

UNITED STATES DEPARTMENT OF COMMERCE
United States Patent and Trademark Office


August 08, 2006

THIS IS TO CERTIFY THAT ANNEXED IS A TRUE COPY FROM THE
RECORDS OF THIS OFFICE OF A DOCUMENT RECORDED ON
NOVEMBER 7, 2005.

By Authority of the
Under Secretary of Commerce for Intellectual Property
and Director of the United States Patent and Trademark Office



T. LAWRENCE
Certifying Officer



PATENT ASSIGNMENT

Electronic Version v1.1
 Stylesheet Version v1.1

SUBMISSION TYPE:	NEW ASSIGNMENT												
NATURE OF CONVEYANCE:	ASSIGNMENT												
CONVEYING PARTY DATA													
<table border="1"> <thead> <tr> <th>Name</th> <th>Execution Date</th> </tr> </thead> <tbody> <tr> <td>Piotr Mirowski</td> <td>07/22/2005</td> </tr> <tr> <td>Daniel Tetzlaff</td> <td>08/31/2005</td> </tr> <tr> <td>David McCormick</td> <td>08/31/2005</td> </tr> <tr> <td>Nneka Williams</td> <td>08/30/2005</td> </tr> <tr> <td>Claude Signer</td> <td>08/31/2005</td> </tr> </tbody> </table>		Name	Execution Date	Piotr Mirowski	07/22/2005	Daniel Tetzlaff	08/31/2005	David McCormick	08/31/2005	Nneka Williams	08/30/2005	Claude Signer	08/31/2005
Name	Execution Date												
Piotr Mirowski	07/22/2005												
Daniel Tetzlaff	08/31/2005												
David McCormick	08/31/2005												
Nneka Williams	08/30/2005												
Claude Signer	08/31/2005												
RECEIVING PARTY DATA													
<table border="1"> <tr> <td>Name:</td> <td>Schlumberger Technology Corporation</td> </tr> <tr> <td>Street Address:</td> <td>38 Old Quarry Road</td> </tr> <tr> <td>City:</td> <td>Ridgefield</td> </tr> <tr> <td>State/Country:</td> <td>CONNECTICUT</td> </tr> <tr> <td>Postal Code:</td> <td>06877-4108</td> </tr> </table>		Name:	Schlumberger Technology Corporation	Street Address:	38 Old Quarry Road	City:	Ridgefield	State/Country:	CONNECTICUT	Postal Code:	06877-4108		
Name:	Schlumberger Technology Corporation												
Street Address:	38 Old Quarry Road												
City:	Ridgefield												
State/Country:	CONNECTICUT												
Postal Code:	06877-4108												
PROPERTY NUMBERS Total: 1													
<table border="1"> <thead> <tr> <th>Property Type</th> <th>Number</th> </tr> </thead> <tbody> <tr> <td>Application Number:</td> <td>11180191</td> </tr> </tbody> </table>		Property Type	Number	Application Number:	11180191								
Property Type	Number												
Application Number:	11180191												
CORRESPONDENCE DATA													
Fax Number: (617)252-4780 <i>Correspondence will be sent via US Mail when the fax attempt is unsuccessful.</i> Phone: 617-252-4717 Email: JConner2@boston.oilfield.slb.com Correspondent Name: Schlumberger-Doll Research Address Line 1: 38 Old Quarry Road Address Line 4: Ridgefield, CONNECTICUT 06877-4108													
ATTORNEY DOCKET NUMBER:	60.1621 US NP												
NAME OF SUBMITTER:	James J. Conner												

CH \$40.00 11180191

500059105

PATENT
 REEL: 016741 FRAME: 0762

Total Attachments: 6

source=60.1621 US NP Assign#page1.tif

source=60.1621 US NP Assign#page2.tif

source=60.1621 US NP Assign#page3.tif

source=60.1621 US NP Assign#page4.tif

source=60.1621 US NP Assign#page5.tif

source=60.1621 US NP Assign#page6.tif

315

PATENT
REEL: 016741 FRAME: 0753

317
316

ASSIGNMENT

WHEREAS, I/We, **Piotr Mirowski**, a citizen of France, residing at 25 Indian Road, Apt. 1E, New York, New York 10034; **Daniel Tetzlaff**, a citizen of the United States, residing at 9538 Beverlyhill St., Houston, Texas 77063; **David McCormick**, a citizen of the United States, residing at 18 Bromfield Road, Acton, Massachusetts 01720; **Nneka Williams**, a citizen of the United States, residing at 255 Massachusetts Avenue, Apt. 709, Boston, Massachusetts 02115; and **Claude Signer**, a citizen of Switzerland, residing at 265 Willow Avenue, Somerville, Massachusetts 02144, have invented

COMPUTER-BASED GENERATION AND VALIDATION OF TRAINING IMAGES FOR MULTIPOINT GEOSTATISTICAL ANALYSIS

as described and set forth in a U.S. Patent Application, filed July 13, 2005, Serial No. 11/180,191 (Attorney Docket No. 60.1621 US NP).

AND WHEREAS, **SCHLUMBERGER TECHNOLOGY CORPORATION**, its successors and assigns (COMPANY), a corporation organized, incorporated and existing under the laws of Texas, and having a place of business at 36 Old Quarry Road, Ridgefield, CT 06877-4108, U.S.A., wants to acquire or confirm its acquisition of the entire right, title and interest in this invention, inventions or improvements, application, and any patent, both in the United States and all foreign countries;

NOW, THEREFORE, TO ALL WHOM IT MAY CONCERN, BE IT KNOWN, that I/we, the inventor(s), for good, sufficient and valuable considerations, assign, transfer and convey to the COMPANY the entire right, title and interest throughout the world, in my/our invention as described in such an application, including the right to file foreign applications under the provisions of any convention or treaty; any confirmation, divisional, continuation, continuation-in-part, or substitute application which may be filed on this invention anywhere; and any patents, certificates, utility models, reissues, extensions, additions or confirmations which may be granted anywhere for the invention, TO HAVE AND TO HOLD the same to the full end of the term or terms for which any such patent may be issued.

AND I/we authorize and request the appropriate authority to issue any related patent to the COMPANY as the assignee of the entire right, title and interest in the patent, for the sole use and benefit of the COMPANY.

AND I/we covenant and warrant that I/we have full right to convey the entire right, title and interest in this invention free and clear of all licenses, encumbrances or liens, and that I/we have not executed and will not execute any instruments in conflict with this agreement.

AND I/we agree that I/we, my/our executors, administrators, or other personal representatives, shall do whatever is legally necessary (make all rightful oaths, execute, and deliver any and all other instruments in writing, and any and all further applications, papers, powers, affidavits, assignments, disclaimers and other documents) in the opinion of counsel for the COMPANY, to secure and vest in the

PATENT
REEL: 016741 FRAME: 0754

328
317

COMPANY, the entire right, title and interest in this invention, inventions, or improvements, application or applications, patents, rights, titles, benefits, privileges and advantages.

IN WITNESS WHEREOF, I sign this 22 day of July 2005.

Piotr Mirowski
Piotr Mirowski

STATE OF CONNECTICUT)
)
COUNTY OF FAIRFIELD)

BE IT KNOWN, that on this 22nd day of July, 2005,
Piotr Mirowski personally appeared to me and executed this assignment.

Ruth A. Schreiber
Ruth A. Schreiber

SEAL

RUTH A. SCHREIBER
NOTARY PUBLIC - CONNECTICUT
My Commission Expires July 31, 2010

PATENT
REEL: 016741 FRAME: 0765

319
318

IN WITNESS WHEREOF, I sign this 31 day of August 2005.

Daniel Tetzlaff
Daniel Tetzlaff

Commonwealth
STATE OF Massachusetts)
COUNTY OF Norfolk)

BE IT KNOWN, that on this 31st day of August, 2005,
Daniel Tetzlaff, personally appeared to me and executed this assignment.

Carol Judith Vanik
Notary Public

Carol Judith Vanik
Notary Public, Massachusetts
My Commission Expires January 12, 2010

SEAL

PATENT
REEL: 016741 FRAME: 0756



Assignment
Application Filing Date: July 13, 2005

Attorney Docket No. 60.1621 US NP
Page 4 of 6


320
319


IN WITNESS WHEREOF, I sign this 31 day of August 2005.


David McCormick

Cornwall
STATE OF Massachusetts)
COUNTY OF Norfolk)

BE IT KNOWN, that on this 31st day of August, 2005,
David McCormick personally appeared to me and executed this assignment.




Notary Public

SEAL

PATENT
REEL: 016741 FRAME: 0767

321
320


IN WITNESS WHEREOF, I sign this 30 day of August 2005.


Nneka Williams.

~~CANONICAL~~ Massachusetts
STATE OF)
Middlesex
COUNTY OF)

BE IT KNOWN, that on this 30th day of August
2005, Nneka Williams personally appeared to me and executed this assignment.

Carol Judith Vozit
Notary Public, Massachusetts
My Commission Expires January 12, 2010



Notary Public

SEAL

PATENT
REEL: 016741 FRAME: 0758

522
321

IN WITNESS WHEREOF, I sign this 31 day of August 2005.




Claude Signer.

Commonwealth of Massachusetts
STATE OF _____)
Middlesex
COUNTY OF _____)

BE IT KNOWN, that on this 31st day of August
2005, Claude Signer personally appeared to me and executed this assignment.

Carol Judith Venti
Notary Public, Massachusetts
My Commission Expires January 12, 2010



Notary Public

SEAL

RECORDED: 11/07/2005

PATENT
REEL: 016741 FRAME: 0759

322

REPUBLICA DE COLOMBIA
SUPERINTENDENCIA DE INDUSTRIA Y COMERCIO

Folio 323

2020
Bogotá D.C.,

Doctor(a)
LLORED A RICAURTE ALICIA
Apoderado(a) y/o Representante de
SCHLUMBERGER HOLDINGS LIMITED

REFERENCIA	Radicación No. 06 68235
	Trámite 2
	Evento 1
	Actuación 416
	Oficio No. 3242
	Folios 1

Teniendo en cuenta que la solicitud de privilegio de patente que se tramita bajo el expediente indicado en la referencia, reúne los requisitos de forma establecidos en los artículos 26 y 27 de la Decisión 486 de la Comisión de la Comunidad Andina, y en las demás disposiciones vigentes sobre la materia, se envía el extracto de la solicitud a la Oficina de Comunicaciones para efecto de su publicación en la Gaceta de Propiedad Industrial.

De acuerdo con lo previsto por el artículo 40 de la Decisión 486/00, la publicación en este caso se hará a partir del día 13 del mes de Enero de 2008.

Cúmplase
Dado en Bogotá DC,

25 JUN 2007

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

adpa10