

TRATAMIENTO DIGITAL DE IMÁGENES E INTELIGENCIA ARTIFICIAL APLICADOS A LA PERFORACIÓN DE POZOS PETROLEROS

Laura Viviana Galvis Carreño¹, Henry Arguello Fuentes², Darwin Mateus Tarazona³

RESUMEN

Los avances en el procesamiento de datos aplicados en el área de perforación de pozos han sido grandes debido al auge de las tecnologías y a la inversión en investigación que realiza esta industria. Actualmente se realizan mediciones y monitoreos y se toman decisiones basadas en los resultados obtenidos de procesar e interpretar los datos tomados por diferentes herramientas dentro del pozo. Aunque diversas técnicas de procesamiento de imágenes han sido aplicadas en la industria petrolera, no están documentadas en la literatura la estimación de la profundidad de derrumbes o cavings en pozos petroleros. Este artículo describe la forma como se han aplicado diferentes técnicas computacionales, principalmente aquellas que involucran el reconocimiento de patrones a través del tratamiento digital de imágenes y la inteligencia artificial en la industria petrolera, especialmente en los procesos de exploración y perforación y, finalmente plantea una propuesta de trabajo de investigación que puede contribuir a mitigar riesgos asociados a estabilidad de pozo, facilitando la toma de decisiones en tiempo real y permitiendo realizar acciones apropiadas de prevención o remediación cuando estas son requeridas, aplicando el procesamiento de imágenes y el uso de técnicas computacionales como el reconocimiento de patrones en la estimación de la profundidad de derrumbes en pozos petroleros.

Palabras clave: Tratamiento digital de imágenes, Inteligencia artificial, reconocimiento de patrones, Pozos petroleros, Rocas, Derrumbes, Recortes de roca.

ABSTRACT

Advances in data processing applied in the drilling area have been high due to the rise of technology and investment in research conducted by the industry. Currently, measurements and monitoring are performed and decisions are made based on the results of processing and interpreting the data collected by different tools into the well. Although various imaging techniques have been applied in the oil industry are not documented in the literature to estimate the depth of landslides or cavings in oil wells. This article describes the way we have applied different computational techniques, especially those that involve pattern recognition through digital image processing and artificial intelligence in the oil industry, especially in exploration and drilling processes, and finally presents a proposal research work can help mitigate risks associated with wellbore stability, facilitating decision making in real time and allowing appropriate preventive actions or remediation when they are required, applying image processing and the use of computational techniques such as pattern recognition in estimating the depth of collapse in oil wells.

Keywords: Digital Image Processing, Artificial Intelligence, Pattern Recognition, Oil Wells, Rocks, Caving, and Cuttings.

1 Candidata a M.Sc. en Ingeniería de Sistemas e Informática. Grupo de Investigación en Ingeniería Biomédica GIIB y Estabilidad de Pozo GIEP. Universidad Industrial de Santander, UIS. Bucaramanga - Colombia. E-mail: laravivis@gmail.com.

2 Máster en Potencia Eléctrica. Grupo de Investigación en Ingeniería Biomédica GIIB. Universidad Industrial de Santander, UIS. Bucaramanga - Colombia. E-mail: henarfu@uis.edu.co.

3 Geólogo. Grupo de Investigación en Estabilidad de Pozo GIEP. Instituto Colombiano del Petróleo, ICP. Bucaramanga - Colombia. E-mail: darwin.mateus@ecopetrol.com.co.

INTRODUCCIÓN

En los últimos años, técnicas de Inteligencia Artificial han sido empleadas para obtener información de ambientes complejos cuyo modelamiento analítico es desconocido. El reconocimiento de patrones como el problema de inferir el estado de un entorno a través de datos previamente tomados y procesados [1],[2] permite realizar estimaciones con un alto grado de precisión que brindan soporte a la toma de decisiones [3].

Durante la planeación del proceso de perforación de un pozo se cuenta con poca información principalmente en cuanto a las características geológicas de la formación y, durante la perforación se presentan dificultades técnicas y comportamientos inesperados a las operaciones realizadas por las personas encargadas; debido a estos problemas el tiempo total que toman estas operaciones están sujetas a considerable incertidumbre y a factores de riesgo [4]. Por esto, el uso de los datos tomados en el proceso de perforación se muestra como una oportunidad para aumentar la probabilidad de éxito y de ser necesario, anticiparse a los posibles problemas con planes de contingencia [3].

La industria del petróleo actualmente hace uso intensivo de la tecnología y para hacerlo necesita el soporte y cooperación de muchas disciplinas [5], especialmente aquellas que implican procesamiento de datos. Por lo anterior, las técnicas computacionales que involucran la inteligencia artificial y el tratamiento digital de imágenes que han sido ampliamente utilizadas en diferentes áreas del conocimiento, hacen parte hoy de soluciones a problemas en la industria del petróleo [6],[7],[8],[9].

Este artículo está organizado de la siguiente manera, en la primera sección se realiza una descripción del proceso de perforación de pozos petroleros y el monitoreo de ripios que se realiza en superficie; en la segunda sección se presenta la forma como técnicas computacionales han sido aplicadas en esta área y en la última sección se describe en forma general como funcionan el reconocimiento de patrones y la inteligencia artificial, en búsqueda de proponer una solución a un problema importante para las compañías petroleras.

PERFORACIÓN DE POZOS PETROLEROS

El sector petrolero es considerado como una de las áreas de interés más importantes para la economía mundial y esta industria es considerada en términos de capacidad como una de las más grandes y al mismo tiempo una de las más sofisticadas en el mundo. Los procesos que envuelve

esta industria están relacionados con la perforación, el almacenamiento, el transporte y el procesamiento de crudos⁴ y su tendencia es la aplicación de diferentes mediciones en tiempo real y la optimización de las operaciones de producción con el propósito de garantizar procesos seguros, efectivos y de bajo costo [10].

Las compañías de petróleo y gas gastan cerca de 20 billones de dólares anualmente en sus procesos de perforación y una parte significativa de entre 15% y 30% es designada para pérdidas que incluyen material como equipo de perforación y continuidad de los procesos de perforación o también llamado tiempo no productivo [11]. Una parte importante de estos costos son asociados al tiempo que se utiliza en la toma de datos, el análisis de los mismos, las tareas de discusión y toma de decisiones que ocurren mientras en operación se esperan ordenes [5].

Así, el tiempo total que toman las operaciones de perforación de pozos está sujeto a constante incertidumbre y a factores de riesgo debido al limitado conocimiento acerca de las características geológicas de la formación, dificultades técnicas y a los comportamientos inesperados del pozo como respuesta a las operaciones humanas realizadas para su perforación.

La perforación de un pozo de petróleo se realiza a través de un equipo especial, las rocas son perforadas por la acción de la rotación y el peso aplicado a un taladro en el extremo de una tubería como se muestra en la figura 1. Los fragmentos de roca o ripios⁵ son continuamente removidos a través de un fluido de perforación que se inyecta al pozo y que vuelve a la superficie por el espacio existente entre las paredes del pozo y la tubería de perforación [4], en el sentido mostrado en la figura 2.




Figura 1. Perforación de un pozo por la acción de rotación y el peso aplicado a un taladro en el extremo de la tubería.

4 Para mayor información diríjase a EconomyWatch Economy, Investment and Financial Reports: <http://www.economywatch.com>

5 Fragmentos de roca compuestos por recortes o cuttings y derrumbes o cavings.




Figura 2. Movimiento del fluido entre la pared del pozo y la tubería de perforación.

Los fragmentos de roca removidos por el equipo de perforación se denominan recortes o cuttings en inglés, y las piezas de roca que se desprenden de la pared del pozo derrumbes o cavings en inglés. Los rípios compuestos por cuttings y cavings son examinados en pozo por técnicos expertos con el fin de evaluar cuando un problema está ocurriendo durante el proceso de perforación, analizando el volumen, la forma y el tamaño. Así, situaciones en las que se presentan diferentes patrones a los normales conocidos pueden indicar la presencia de algunas anomalías como el colapso de las paredes del pozo [10].

En Colombia, por ejemplo Ecopetrol⁶ realiza actualmente este tipo de monitoreo en superficie y genera reportes diarios que permiten caracterizar los rípios que salen con el lodo de perforación, estos son analizados teniendo en cuenta los factores de forma o morfología, volumen y tamaño, y con esta información se contribuye en la toma de decisiones respecto a los planes de perforación u operación a seguir (Ver figura 3).

Mediante estos controles es posible saber que el pozo está por ejemplo, teniendo problemas de derrumbes. Por esto, obtener información mucho más acertada sobre cuando y en donde se está presentando este fenómeno es importante para las empresas que operan pozos, y tener los medios para la obtención de esta información es en este momento un objetivo clave en la industrial petrolera.

⁶ Ecopetrol: principal compañía petrolera en Colombia. Pertenece al grupo de las 40 petroleras más grandes del mundo y es una de las cuatro principales de Latinoamérica. Sitio Web: <http://www.ecopetrol.com.co/>.




Figura 3. Rípios en superficie, pueden distinguirse diferentes formas, tamaños y volúmenes.

Durante el proceso de perforación se generan datos que usa el ingeniero de perforación y el geólogo encargado para tomar decisiones basadas en su experiencia; sin embargo, es usual hoy en día procesar esos datos para generar información que permita una mejor toma de decisiones. Las nuevas tecnologías en mediciones durante la perforación, adquisición, transferencia de datos y velocidad de cómputo dan la oportunidad de contar con información precisa para esa toma de mejores decisiones [3], motivada por lo anterior y por el crecimiento de los costos en sus operaciones de perforación la industria del petróleo ha mostrado una tendencia hacia la toma de mediciones y control en tiempo real [8].

Con el rápido desarrollo de la ciencia y la tecnología, los recursos de información son cada vez mayores, por esto la importancia de las predicciones en sistemas reales. Si estas predicciones pueden llegar a ser precisas, entonces se provee de bases científicas a la tarea racional de toma de decisiones [12].

Estas mediciones obtenidas en tiempo real durante la perforación son interpretadas por herramientas computacionales diseñadas específicamente para tales propósitos. Esto facilita el análisis y ayuda a los encargados a llevar su trabajo adelante de una manera eficiente y efectiva, teniendo como premisa el hecho de que los peligros se pueden identificar con anticipación, de modo que los operadores pueden desarrollar planes de contingencia para enfrentarlos [13].

TÉCNICAS COMPUTACIONALES EN PROCESOS DE PERFORACIÓN

Con el aumento de la tecnología, se ha prestado aún más atención a la exploración y perforación de pozos, en búsqueda de mitigar los problemas que puedan presentarse y de monitorear las diferentes actividades que se llevan a cabo durante los mismos. Para esto desde hace unos años diversos estudios y trabajos de investigación han sido desarrollados con el fin de aplicar técnicas computacionales en estos procesos de la industria petrolera.

Es así como por ejemplo T. Gao, J. Cao, M. Zhang y J. Qi. [14] trabajaron en un método para la extracción de características de litología usando la relación entre la tendencia de variación de la curva de valores de perforación estimados en tiempo real y el material básico de diversas litologías, esto a través de una red de Hamming de adaptación fuzzy, evitando de esta manera las carencias existentes en el método común basado en los registros de curvas y la estimación humana. De igual forma a través de adaptación fuzzy, Q. Zhao, F. Wang, W. Wang y H. Deng [15] trabajaron en un sistema automático de perforación para el control de plataformas de perforación petrolera.

Para la detección de fracturas naturales a través de imágenes de pozo Kherroubi [16] aplicó el tratamiento de imágenes inicialmente con la detección de altos contrastes, luego el cálculo de la orientación de la fractura principal y finalmente mediante un algoritmo de clustering se identificaron aquellas fracturas que correspondían a fracturas naturales.

Por otro lado, durante el proceso de producción de un pozo, se ha trabajado en la estimación de la producción de campos petroleros a través de redes neuronales con gran efectividad [17],[18]. Teniendo en cuenta que este es un valor de un sistema no lineal e incierto y que depende de varios factores como la profundidad efectiva, la permeabilidad, la porosidad y el contenido de agua o como Gou y Deng lo plantean [19] donde a través de métodos de regresión múltiple y variables como la tasa de producción y la producción de años anteriores, entre otras, se realizó la predicción con precisión de la producción de un pozo petrolero.

Otros trabajos han buscado el monitoreo de procesos de perforación en pozos de petróleo [20],[21],[22],[4],[23],[8]. En el trabajo de Shang [24], mediante el procesamiento de imágenes se detectaron

minerales en arenas de pozos petroleros, pero solo en el estudio realizado por Guilherme, et al. [25] enfocó en el análisis de imágenes de recortes, en el que se clasifican en tres clases de volúmenes la cantidad de recortes en intervalos determinados de tiempo, este significativo aporte en el análisis de imágenes de recortes pretende ser ampliado con el trabajo que se propone en este artículo como resultado de la revisión de estado del arte realizada.

Como puede verse, el reconocimiento de patrones aplicado a los procesos de perforación se muestra como un área de investigación importante debido a que puede tener precisión durante la operación de perforación y además porque permite desarrollar métodos de bajo costo y no invasivos, dado que solo requieren de un equipo compuesto por un sistema de adquisición y un computador con los respectivos algoritmos.

RECONOCIMIENTO DE PATRONES E INTELIGENCIA ARTIFICIAL

Las técnicas de Inteligencia Artificial han sido empleadas para la obtención de información de ambientes complejos o problemas cuyo modelamiento analítico es desconocido y que requieren de la simulación de la Inteligencia humana [26].

El reconocimiento de patrones como el problema de inferir el estado de un entorno a través de datos previamente tomados y procesados permite realizar estimaciones con un alto grado de precisión que brindan soporte a la toma de decisiones [1].

Esta disciplina científica cuyo objetivo es la clasificación de objetos en un número de categorías o clases, ha sido fundamental en los últimos años y ha permitido que sea natural el hecho de tratar de diseñar y construir máquinas capaces de reconocer patrones, desde el reconocimiento de voz, la identificación de huellas dactilares, el reconocimiento óptico de caracteres, hasta la identificación de secuencias de ADN entre otras [27].

Dependiendo de la aplicación, los objetos a ser clasificados pueden ser imágenes, señales o cualquier tipo de medida que necesite ser clasificada, y estos objetos suelen referirse como patrones.

Para que estos sistemas lleven a cabo la tarea específica para la que fueron creados, deben diseñarse de la siguiente manera: Primero, un dispositivo debe capturar los datos

a procesar, luego, estos deben ser preprocesados con el fin de resolver tres problemas: (i) la reducción de ruido, (ii) la eliminación de superficies no deseadas y (iii) compensar pérdidas de propagación [28], simplificando las siguientes operaciones sin pérdida de información relevante, luego los datos deben enviarse a un extractor de características, cuyo propósito es reducir los datos mediante la medición de ciertas “propiedades”. Estas características (o más precisamente, los valores que representan estas características) son enviadas a un clasificador que evalúa estos datos y toma una decisión final acerca de la clase a la que pertenecen [29].

A. PREPROCESADO DE DATOS

Normalización de Datos: En situaciones prácticas el diseñador debe enfrentarse a características cuyos valores se encuentran entre rangos dinámicos. Por esta razón valores de características muy grandes pueden tener una mayor influencia en las funciones de costo que las que presentan valores pequeños, aunque esto puede no reflejarse necesariamente en el comportamiento del clasificador. Este problema se supera mediante la normalización de las características para prevenir que algunas dominen sobre las otras y se obtengan valores en rangos fácilmente comparables. Una técnica sencilla es la normalización a través de los respectivos cálculos de la media y la varianza. Así, para N datos disponibles y l características se tiene:

$$\bar{x}_k = \frac{1}{N} \sum_{i=1}^N x_{ik}, \quad k = 1, 2, \dots, l \quad (1)$$

$$\sigma_k^2 = \frac{1}{N-1} \sum_{i=1}^N (x_{ik} - \bar{x}_k)^2 \quad (2)$$

$$\hat{x}_{ik} = \frac{x_{ik} - \bar{x}_k}{\sigma_k} \quad (3)$$

donde X_{ik} son los valores a normalizar, \bar{x}_k y σ_k^2 son la media y la varianza de los valores de la k -ésima característica y \hat{x}_{ik} es el nuevo valor normalizado.

De esta forma, todas las características normalizadas tendrán una media de 0 y una varianza de 1. Este, es un método lineal, otras técnicas limitan los valores de las características en el rango de $[0,1]$ o $[-1,1]$ mediante la escala adecuada.

Estas técnicas lineales son ampliamente usadas, está por ejemplo el caso de N. Singh, T. Singh, A. Tiwary y K. Sarkar. [30], donde se normalizan los valores de las características entre $[-1,1]$ para luego servir de entrada a una red neuronal, [31], quien también normaliza entre $[-1,1]$ para clasificar huellas, [32] quien normaliza entre $[0,1]$ para clasificar objetos enterrados o como P. Viswanath, M. Narasimha Murty y S. Bhatnagar [33], quienes trabajaron con una base de datos normalizada de forma lineal para clasificación de imágenes de hojas escritas a mano.

Además de los métodos lineales, existen métodos no lineales que se emplean en los casos en los que los datos no se encuentran distribuidos alrededor de la media. En estos casos, las transformaciones se basan en funciones no lineales como la logarítmica o la sigmoideal, las cuales se pueden utilizar para llevar los datos dentro de intervalos específicos. El escalamiento softmax [27] es un método popular que consiste en dos pasos:

$$y = \frac{x_{ik} - \bar{x}_{ik}}{r\sigma_k}, \quad (4)$$

$$\hat{x}_{ik} = \frac{1}{1 + \exp(-y)}$$

donde X_{ik} son los valores a normalizar, \bar{x}_k es la media de los valores de la k -ésima característica, σ_k es la desviación estándar, y es el grado de escalamiento de cada valor, proporcional a la distancia que ese valor tenga hacia la media y \hat{x}_{ik} es el nuevo valor normalizado.

Esta transformación es básicamente una función de aplastamiento o compresión que limita los datos entre el rango $[0, 1]$. Para valores pequeños de y esta es una aproximación de una función lineal con respecto de X_{ik} . El rango de valores de X_{ik} que corresponde a la sección lineal depende de la desviación estándar y el factor r , el cual es definido por el usuario. Los valores por fuera de la media se comprimen exponencialmente.

Falta de Datos: En la práctica, el número de datos disponible no es necesariamente el mismo para todas las características. Si el número de datos de entrenamiento es lo suficientemente alto, se puede optar por descartar algunos de ellos y mantener el mismo número de datos para todas las características. Sin embargo, en la mayoría de los casos los datos son limitados. En esos casos los datos faltantes pueden predecirse de forma heurística. Una forma sencilla es reemplazar los datos

faltantes con la media correspondiente, calculada con los valores disponibles de las características respectivas [27]. Existen otras técnicas un poco más elaboradas, pero no se mencionan porque no hacen parte del tema principal de este artículo.

B. EXTRACCIÓN DE CARACTERÍSTICAS EN IMÁGENES

Imagen: Una imagen bidimensional es una matriz (2 dimensiones) de píxeles. El valor de cada píxel es proporcional a la luminosidad del punto que corresponde en la escena; su valor se deriva generalmente de la salida de un convertidor análogo-digital. Es usualmente cuadrada y puede describirse como $N \times N$ píxeles de m bits, donde N es el número de puntos en cada una de las dimensiones y m controla los valores de luminosidad [34].

Para realizar la comparación entre dos imágenes, características visuales deben ser extraídas. El objetivo de esta extracción es doble. Primero, se mapean las imágenes en un espacio común donde pueden ser comparadas de forma más sencilla. Segundo, se reduce la dimensionalidad del espacio manteniendo solo la información relevante.

Gran cantidad de características visuales pueden ser previstas: color, textura, forma, etc. La selección de estas características depende del tipo de imagen con la que se esté trabajando [35].

Es el caso por ejemplo de F. Del Frate, F. Pacifici, G. Schiavon y C. Solimini [36] quienes exponen en su trabajo la clasificación automática de colecciones de imágenes de satélites de muy alta resolución, en las que utiliza análisis basado en el color de píxeles para su clasificación en una de las siguientes clases: edificio, vegetación, suelo descubierto o asfalto, o el caso en el que se buscan clasificar grados de cataratas, teniendo en cuenta características de color extraídas de imágenes microscópicas [37].

Un problema asociado al reconocimiento de patrones es la dimensionalidad, el número de características con que dispone el diseñador de un sistema de clasificación es usualmente muy grande. Hay más de una razón por la que se hace necesario reducir el número de estas características a un mínimo suficiente. La complejidad computacional es una de ellas, otra razón es que aunque dos características pueden llevar a una muy buena clasificación de información al ser tratadas por separado, hay pocos beneficios si se combinan en un vector de

características, a causa de una posible correlación. Otra razón importante es la impuesta por la propiedad de generalización del clasificador [27].

Ahora bien, dado un número de características, ¿Cómo se pueden seleccionar las más importantes en busca de reducirlas y al mismo tiempo retener tanta información representativa de la clase como sea posible?, para esto se lleva a cabo la extracción de características.

C. EXTRACCIÓN DE CARACTERÍSTICAS EN ROCAS

Cada característica extraída determina la propiedad comparativa que hace distinto a un objeto de otro. Estas medidas que son las entradas para la clasificación, son usadas en forma de un vector de características, en donde l representa el número de características $Z_i, i=1,2,3,\dots,l$:

$$z = \begin{pmatrix} z_1 \\ z_2 \\ \vdots \\ z_l \end{pmatrix} \quad (6)$$

Cada uno de estos vectores identifica únicamente a un solo patrón (Objeto).

Investigadores han tomado la detección de rocas como un problema de reconocimiento de patrones, se plantea que su análisis es aparentemente sencillo porque los objetivos son unidades discretas que tienen propiedades físicas medibles y ocupan un lugar preciso, pero que desafortunadamente las rocas al igual que otras características de interés geológico son difíciles de clasificar debido a que al querer identificar las características específicas dadas por sus propiedades físicas, las condiciones de ruido e iluminación dificulta la extracción de estas propiedades [38]; sin embargo, diferentes investigaciones han sido llevadas a cabo en esta área [39],[40],[41],[42],[9], y el trabajo que se propone en este artículo está precisamente enfocado al análisis de imágenes de rocas.

El análisis basado en textura ha sido ampliamente aceptado como una característica significativa en el campo de procesamiento digital de imágenes y ha sido adoptado por diversos autores. Marmo, et al. [43] utilizaron la textura para identificar rocas carbonatadas y para su medición se basaron en 23 parámetros sobre imágenes digitales en tonos grises entre los que se

encuentran el porcentaje de frecuencia de tonos grises, el número de áreas blancas, entre otras; por otro lado, Kachanuban y Udomhunsakul [44] utilizaron la medida de frecuencia espacial de imágenes para analizar y clasificar texturas de rocas en tres grupos.

En búsqueda de clasificar en tres clases de volúmenes de cuttings y utilizando imágenes, Marana, et al. [10] realizaron un análisis de textura para crear un vector de características, el cual se compone de cuatro parámetros o descriptores texturales de Haralick⁷ [45]: energía, entropía, homogeneidad y contraste.

En búsqueda de estimar la clase de textura de roca, N. Singh, T. Singh, A. Tiwary y K. Sarkar [30] tomaron 27 parámetros numéricos entre estadísticos (intensidad media, desviación estándar, suavidad) de imagen (porcentaje de frecuencia de tonos grises, número de áreas blancas, número de píxeles en áreas blancas) y de región (área del objeto, extensión y solidez).

El color también ha sido ampliamente utilizado, [46] y T. Mengko, Y. Susilowati, R. Mengko y B. Leksono. [47] utilizaron histogramas de color, en busca de identificar minerales en rocas, teniendo en cuenta que la intensidad de ciertos colores representa la existencia de minerales en la roca.

R. Crida y G. De Jager [48] se utilizaron 12 características de región como intensidad de borde, área de la superficie, discontinuidad de borde, entre otros, en búsqueda de reconocer la región de la imagen en la que se encuentra la roca.

Autores como D. Thompson, S. Niekum, T. Smith y D. Wettergreen [38] han optado por crear vectores de características con diferentes propiedades, en este caso se usa color, textura y forma para detectar presencia de rocas en imágenes.

Un análisis un poco diferente fue llevado a cabo por S. Hoseinie, M. Ataei y M. Osanloo [49], quienes realizaron un consenso entre opiniones de expertos de varios países con experiencia en perforación para determinar los parámetros más importantes de las rocas respecto a la capacidad de ser perforadas, entre 21 parámetros fueron seleccionados 12 divididos entre características de textura como el tipo de textura,

⁷ Conjunto de medidas de textura basadas en la matriz de co-ocurrencia. Son de naturaleza estadística y para su cálculo, es necesario asumir que la totalidad de la información textural de una imagen está contenida en las relaciones espaciales que se dan entre los distintos niveles de gris de un objeto.

tamaño de grano y forma, tipo de matriz y grado de cementación, características físicas como densidad, porosidad y desgaste y, características mecánicas como resistencia a la compresión y a la tensión, contenido de cuarzo, elasticidad y plasticidad y dureza. Además, bajo las premisas (i) el número de parámetros a usar debe ser pequeño y (ii) parámetros equivalente se deben evitar, se consideraron cinco características seleccionadas mediante pruebas estándar: abrasividad, dureza, textura, tamaño de grano y módulo de Young.

APRENDIZAJE Y ADAPTACIÓN

Cualquier método que incorpora información de muestras de entrenamiento en el diseño de un clasificador emplea aprendizaje. La creación de clasificadores entonces, implica postular algún tipo general de modelo o forma del clasificador y el uso de patrones de entrenamiento para aprender o estimar los parámetros desconocidos del modelo. El aprendizaje se refiere a algún tipo de algoritmo para reducir el error en el conjunto de datos de entrenamiento, y, viene en varias formas generales [29]:

- *Aprendizaje Supervisado*: Se proveen ejemplos de dos o más grupos de objetos (conjunto de entrenamiento), cada uno estos ejemplos es categorizado y luego el clasificador es entrenado con estos ejemplos para crear un conjunto de reglas o modelo matemático que pueda luego clasificar otros ejemplos de los que desconoce su categoría.
- *Aprendizaje No Supervisado*: También llamado Clustering, los ejemplos que se proveen como conjunto de entrenamiento no están categorizados, la técnica debe agrupar los datos además de crear el conjunto de reglas o ecuaciones matemáticas para distinguir los grupos entre sí.

CLASIFICACIÓN

La clasificación se basa en el establecimiento de criterios que se pueden utilizar para identificar o caracterizar las diferentes poblaciones de los objetos de estudio.

En cuanto a clasificación de rocas investigaciones realizadas para la clasificación de rocas, muestran una gran variedad de técnicas utilizadas que van desde métodos convencionales de clasificación hasta algoritmos mejorados creados por sus autores.

Marana et al. [10] se compara el rendimiento que proporcionan una colección de clasificadores supervisados: Optimum-path forest (OPF), Red neuronal

artificial con perceptrones multicapa (ANN-MLP), Máquinas de soporte vectorial (SVM) y Clasificador Bayesiano (BC), obteniendo como resultado general que OPF supera en precisión y eficiencia a todos los demás, se muestra superior a ANN-MLP y similar a SVM pero mucho más rápido.

El trabajo desarrollado en N. Singh, T. Singh, A. Tiwary y K. Sarkar [30] utilizó las redes neuronales artificiales como clasificador y predijo el tipo de textura de imágenes con un 92% de precisión. De la misma forma R. Marmo, S. Amodio y R. Tagliaferri y V. Ferreri, G. Longo [43] también usó redes neuronales artificiales para clasificar texturas de rocas carbonatadas y obtuvo un 93% de precisión en sus pruebas, lo que muestra que las redes neuronales hacen un trabajo satisfactorio.

CONCLUSIONES Y DISCUSIÓN

Se presentaron a través del artículo las diferentes formas en que son empleadas técnicas computacionales principalmente en la industria petrolera, esto muestra el auge que tienen en esta área y la gran importancia que tiene la investigación en los diferentes procesos que la componen.

Mediante la realización de este artículo, se encontró que uno de los problemas conocidos en la industria petrolera, el de derrumbes en las paredes del pozo [25] no ha sido tratado, actualmente solo es posible detectarlos mediante el monitoreo de recortes en superficie realizado por expertos, sin embargo no es posible conocer la profundidad a la que se está presentando para tomar alguna medida que solucione el problema, por lo que se hace necesario el uso de nuevas técnicas computacionales que permitan obtener estimaciones y que puedan llevar a una toma de decisiones oportuna [50].

De acuerdo a lo anterior se plantea la realización, para trabajos futuros, de una investigación centrada en la utilización de técnicas de inteligencia artificial para el reconocimiento y clasificación de patrones como una forma de transformar datos de perforación (imágenes de cuttings) para estimar la profundidad de cavings, información útil para la toma de decisiones en pozo.

El tratamiento digital de imágenes es de vital importancia en el desarrollo del trabajo propuesto, teniendo en cuenta los buenos resultados que han obtenido los autores mencionados y al tipo de datos que podrían utilizarse para llevar a cabo este nuevo trabajo.

AGRADECIMIENTOS

Este trabajo es financiado por la Vicerrectoría de Investigación y Extensión de la Universidad Industrial de Santander, mediante el proyecto de investigación con código interno 5537.

REFERENCIAS BIBLIOGRÁFICAS

1. M. Westover, J. O'Sullivan. Achievable rates for pattern recognition. *IEEE Transactions on Information Theory*, 54(1):299-320, 2008.
2. Y. K. Wang, K. C. Fan. Applying genetic algorithms on pattern recognition: an analysis and survey. *Proceedings of the 13th International Conference on Pattern Recognition*, 2:740-744, 1996.
3. O. Vincké, C. Mabile. Interactive drilling: the up-to-date drilling technology. *Oil & Gas Science and Technology*, 59(4):343-356, 2004.
4. D. Coelho, M. Roisenberg, P. Filho, C. Jacinto. Risk assessment of drilling and completion operations in petroleum wells using a monte carlo and a neural network approach. *Proceedings of the Winter Simulation Conference*, paginas 1892-1897, 2005.
5. S. Longbin, M. Xiangbin. The characteristic analysis and design of oil exploration data services in digital oilfield. *2010 International Conference on e-Education, e-Business, e-Management and e-Learning*, paginas 88-92, 2010.
6. C. Chuan-zhi. Genetic algorithm principle and the application in oilfield development. *2010 2nd International Conference on Computer Engineering and Technology ICCET*, 7:585-588, Enero 2010.
7. Z. Weidong, W. Ruihe, L. Huazhou, L. Luopeng. Study on depth prediction of abrasive water jet perforation using back propagation neural network. *2008 IEEE Pacific-Asia Workshop on Computational Intelligence and Industrial Application*, paginas 892-896, Octubre 2008.
8. T. Fonseca, J. Mendes, A. Serapiao, I. Guilherme. A genetic neuro-model reference adaptive controller for petroleum wells drilling operations. *International Conference on Computational Intelligence for Modelling Control and Automation - CIMCA*, 2006.

9. W. Wang, E. Hakami. A segmentation algorithm for rock fracture detection. *Pattern Recognition and Image Analysis*, paginas 580-588, 2005.
10. A. Marana, G. Chiachia, I. Guilherme, J. Papa, K. Miura, M. Ferreira, F. Torres. An intelligent system for petroleum well drilling cutting analysis. *International Conference on Adaptive and Intelligent Systems, 2009. ICAIS '09*, paginas 37-42, 2009.
11. W. Aldred, D. Plumb, I. Bradford, J. Cook, V. Gholkar, L. Cousins, R. Minton, J. Fuller, S. Goraya, D. Tucker. Managing drilling risk. *Oilfield Review*, paginas 2-19, 1999.
12. M. Li, C. Li. A study on application of virtual variables model in the forecasting of material demand in oilfield oil drilling. *The 1st International Conference on Information Science and Engineering - ICISE*, paginas 3737-3740, 2009.
13. T. Bratton, S. Edwards, J. Fuller, L. Murphy, S. Goraya, T. Harrold, J. Holt, J. Lechner, H. Nicholson, W. Standifird, B. Wright. Prevention of problems during drilling. *Oilfield Review*, paginas 33-51, Febrero 2001.
14. T. Gao, J. Cao, M. Zhang, J. Qi. Lithology recognition during oil well drilling based on fuzzy-adaptive hamming network. *Proceedings of the Sixth International Conference on Intelligent Systems Design and Applications ISDA'06*, 2006.
15. Q. Zhao, F. Wang, W. Wang, H. Deng. Adaptive fuzzy control technology for automatic oil drilling system. *Proceedings of the IEEE International Conference on Automation and Logistics*, paginas 2123-2127, Julio 2007.
16. J. Kherroubi. Automatic extraction of natural fracture traces from borehole images. *Pattern Recognition*, Enero 2008.
17. C. Zhu X. Zhao. Application of artificial neural network in the prediction of output in oilfield. *International Joint Conference on Artificial Intelligence, 2009 ICAI'09*, paginas 155-158, 2009.
18. J. Xie, M. Lu, H. Liang, P. Lin. The research and application of bp network tracking model for forecasting oil well yield. *Pacific-Asia Workshop on Computational Intelligence and Industrial Application PACIA'08*, 1:18-22, 2008.
19. L. Guo, X. Deng. Application of improved multiple linear regresión method in oilfield output forecasting. *2009 International Conference on Information Management, Innovation Management and Industrial Engineering*, paginas 133-136, 2009.
20. F. Krepelka, J. Futó, M. Labas. Monitoring of drilling process using acoustic signals. *Acta Montanistica Slovaca*, 3:237-240, 2000.
21. A. Serapiao, R. Tavares, J. Mendes, I. Guilherme. Classification of petroleum well drilling operations using support vector machine (svm). *International Conference on Computational Intelligence for Modelling, Control and Automation, 2006 and International Conference on Intelligent Agents, Web Technologies and Internet Commerce*, 2006.
22. A. Serapiao, J. Mendes, K. Miura. Artificial immune Systems for classification of petroleum well drilling operations. *Proceedings of the 6th international conference on Artificial immune systems*, paginas 47-58, 2007.
23. S. Yilmaz, C. Demircioglu, S. Akin. Application of artificial neural networks to optimum bit selection. *Computers & Geosciences*, 28:261-269, Febrero 2002.
24. H. Shang. Image processing for the oil sands mining industry. *IEEE Signal processing magazine*, paginas 197-200, Diciembre 2008.
25. I. Guilherme, A. Marana, J. Papa, G. Chiachia, L. Afonso, K. Miura, M. Ferreira, F. Torres. Petroleum well drilling monitoring through cutting image analysis and artificial intelligence techniques. *Engineering Applications of Artificial Intelligence*, paginas 1-7, Mayo 2010.
26. C. Ketata, M. Satish, M. Islam. Expert system knowledge Management for laser drilling in the oil and gas industry. *Proceedings of the 2005 International Conference on Computational Intelligence for Modelling, Control and Automation, and International Conference on Intelligent Agents, Web Technologies and Internet Commerce (CIMCA-IAWTIC'05)*, Enero 2005.
27. S. Theodoridis, K. Koutroumbas. Pattern recognition. third edition. paginas 837, 2006.
28. E. Pasolli, F. Melgani, M. Donelli, R. Attoui, M. de Vos. Automatic detection and classification of buried

- objects in gpr images using genetic algorithms and support vector machines. *IEEE International Geoscience and Remote Sensing Symposium. IGARSS 2008*, 2:525-528, 2008.
29. R. Duda, P. Hart, D. Stork. Pattern classification. Second edition. paginas 637, Octubre 2002.
30. N. Singh, T. Singh, A. Tiwary, K. Sarkar. Textural identification of basaltic rock mass using image processing and neural network. *Comput Geosci*, 14(2):301-310, Marzo 2010.
31. J. Hong, J. Min, U. Cho, S. Cho. Fingerprint classification using one-vs-all support vector machines dynamically ordered with naive bayes classifiers. *Pattern Recognition*, 41(2):662-671, 2008.
32. E. Pasolli, F. Melgani, M. Donelli. Automatic analysis of gpr images: A pattern-recognition approach. *IEEE Transactions on Geoscience and Remote Sensing*, 47(7):2206-2217, 2009.
33. P. Viswanath, M. Narasimha Murty, S. Bhatnagar. Fusion of multiple approximate nearest neighbor classifiers for fast and efficient classification. *Information fusion*, 5(4):239-250, 2004.
34. M. Nixon, A. Aguado. Feature extraction & image processing. Second edition. page 399, Noviembre 2008.
35. Y. Maret, F. Dufaux, T. Ebrahimi. Adaptive image replica detection based on support vector classifiers. *Signal Processing: Image Communication*, 21(8):688-703, 2006.
36. F. Del Frate, F. Pacifici, G. Schiavon, C. Solimini. Use of neural networks for automatic classification from high-resolution images. *IEEE Transactions on Geoscience and Remote Sensing*, 45(4):800-809, 2007.
37. H. Shen, H. Hao, L. Wei, Z. Wang. An image based classification method for cataract. *International Symposium on Computer Science and Computational Technology. ISCST '08*, 1:583-586, 2008.
38. D. Thompson, S. Niekum, T. Smith, D. Wettergreen. Automatic detection and classification of features of geologic interest. *IEEE Aerospace Conference*, paginas 366-377, 2005.
39. R. Crida, G. De Jager. Multiscalar rock recognition using active vision. *International Conference on Image Processing*, 2:345-348, 1996.
40. Y. Liang, D. Feng, G. Liu, X. Yang, X. Han. Neural identification of rock parameters using fuzzy adaptive learning parameters. *Computers & Structures*, 81:2373-2382, 2003.
41. D. Thompson, R. Castaño. Performance comparison of rock detection algorithms for autonomous planetary geology. *Aerospace Conference*, paginas 1-9, 2007.
42. Q. Wang, Q. Lin. Rock types detection and classification through the use of orthogonal subspace projection approach. *Geoscience and Remote Sensing Symposium, IGARSS '05*, 4:2910-2913, 2005.
43. R. Marmo, S. Amodio, R. Tagliaferri, V. Ferreri, G. Longo. Textural identification of carbonate rocks by image processing and neural network: Methodology proposal and examples. *Computers & geosciences*, 31:649-659, 2005.
44. T. Kachanuban, S. Udomhunsakul. Natural rock images classification using spatial frequency measurement. *International Conference on Intelligent and Advanced Systems. ICIAS 2007*, paginas 815-818, 2007.
45. R. Haralick, K. Shanmugam, I. Dinstein. Textural features for image classification. *IEEE Transactions on Systems, Man and Cybernetics*, 3(6):610-621, 1973.
46. I. Bajwa, M. Choudhary. A study for prediction of minerals in rock images using back propagation neural networks. *2006 International Conference on Advances in Space Technologies*, paginas 185-189, 2006.
47. T. Mengko, Y. Susilowati, R. Mengko, B. Leksono. Digital image processing technique in rock forming minerals identification. *The 2000 IEEE Asia-Pacific Conference on Circuits and Systems. APCCAS*, paginas 441-444, 2000.
48. R. Crida, G. De Jager. Rock recognition using feature classification. Proceedings of the 1994 *IEEE South African Symposium on Communications and Signal Processing. COMSIG-94*, paginas 152-157, 1994.

49. S. Hoseinie, M. Ataei, M. Osanloo. A new classification system for evaluating rock penetrability. *International Journal of Rock Mechanics and Mining Sciences*, 46(8):1329-1340, 2009.
50. D. Castillo, D. Moos. Reservoir geomechanics applied to drilling and completion programs in challenging environments: North west shelf, timor sea, north sea and Colombia. *APPEA*, paginas 509-521, Abril 2000.

Recepción: 25 de febrero de 2011

Aceptación: 15 de junio de 2011