

# Sensor Virtual basado en Minería de Datos para la Estimación de Parámetros de Pozos Petroleros

Egner Aceros

Facultad de Ingeniería, División de Estudios para Graduados,  
Universidad del Zulia, Maracaibo, 4001, Venezuela

egner.aceros@cantv.net

Edgar Camargo

Petróleos de Venezuela S.A., AIT – Distrito Soc. Tecnológico,  
Maracaibo, 4001, Venezuela  
camargoea@pdvsa.com

José Aguilar

Facultad de Ingeniería, Universidad de Los Andes,  
Mérida, 5101, Venezuela

aguilar@ula.ve

Héctor Lozada

Petróleos de Venezuela S.A. AIT – L. S. Automatización  
Industrial, Lagunillas, 4016, Venezuela  
lozadah@pdvsa.com

**Resumen**—En este trabajo se presenta el diseño de una herramienta computacional que permite estimar la temperatura de subsuelo en un pozo productor de petróleo. En esta oportunidad, el caso de estudio seleccionado corresponde a un pozo con método de levantamiento artificial por bomba electrosumergible. Para lograr la estimación se utilizan las variables disponibles tales como señales eléctricas de corrientes, frecuencia del variador, del proceso tales como la presión de entrada a la bomba, presión de la línea de producción, aplicando minería de datos y técnicas disponibles. Los resultados obtenidos luego de la experimentación con los datos, demuestran el buen desempeño del sensor virtual, en cuanto a la exactitud y generalización de la predicción/clasificación de la temperatura de subsuelo. Con esta herramienta se puede lograr disponer de ahorros cuantificativos al no depender directamente de un sensor físico para lograr esta medición sino ahora de una herramienta computacional.

**Palabras clave**— *Minería de datos, Levantamiento Artificial por Bomba Electrosumergible, Sensor Virtual, Pozo productor de petróleo.*

## I. INTRODUCCION

El uso de las distintas tecnologías de información en las industrias ha dado paso al registro de grandes cantidades de datos para monitorear los procesos asociados. En muchos de esos casos, la mayoría de los casos los datos no son utilizados eficientemente. Por otro lado, las técnicas inteligentes permiten manipular esos almacenamientos masivos de datos, con el objetivo de obtener conocimiento valioso de esas bases de datos, para explotar dicho conocimiento en los procesos de toma de decisiones organizacionales, ya sea en tareas de predicción, clasificación, optimización entre otras.

En este artículo se propone el diseño de un sensor virtual usando técnicas de Minería de Datos (MD) [1-2], las cuales son conocidas por sus capacidades para el descubrimiento de información oculta en grandes masas de datos. Para realizar el proceso completo de extracción del conocimiento sobre datos, se suelen seguir los siguientes pasos: Conocimiento del dominio de la aplicación, establecimiento de los objetivos del proceso de descubrimiento de conocimiento, determinación del

conjunto de datos objetivo, preparación de los datos, y por último, la aplicación de las técnicas de MD.

En particular, en la industria petrolera existe una enorme cantidad de datos históricos sobre lo que ocurre en las instalaciones de producción [3], con una gran cantidad de conocimiento que puede estar inmerso en ellos, razón por la cual el presente trabajo estará enfocado en la extracción de conocimiento desde los sistemas de producción de crudo. Específicamente, se estudia la estimación de la temperatura de subsuelo de entrada a la bomba, debido a que ésta es una variable determinante para la temperatura de trabajo del motor en el subsuelo, pudiendo ser necesario en un momento dado reducir la velocidad en el motor o en caso extremo llegar a detener el equipo por alta temperatura, evitando daños en el motor o en sus componentes. Dicho sensor virtual permite la inferencia de la variable objeto de estudio en el caso en que el sensor real esté fuera de servicio, ampliando la disponibilidad de elementos para la toma de decisiones alrededor de los procesos de producción de petróleo de manera inteligente, partiendo de la utilización de técnicas de extracción de conocimiento desde los datos del proceso industrial.

## II. BASES TEÓRICAS DE LA MINERÍA DE DATOS

La minería de datos o exploración de datos, es un campo de las ciencias de la computación referido al proceso que intenta descubrir patrones en grandes volúmenes de conjuntos de datos. Esta tecnología permite explorar grandes bases de datos, de manera automática o semiautomática, para encontrar patrones repetitivos, tendencias o reglas, que expliquen el comportamiento de los datos en cierto contexto [3]. Para ello, utiliza métodos de la inteligencia artificial, aprendizaje automático, estadística y sistemas de bases de datos. El objetivo general del proceso de minería de datos consiste en extraer información de un conjunto de datos, y transformarla en una estructura comprensible para su uso posterior. Además de la etapa de análisis en bruto, que involucra aspectos de bases de datos y gestión de datos, procesamiento y modelo de datos, considera procesos de inferencia, cálculo de métricas de interés, post-procesamiento de las estructuras descubiertas, visualización de los datos descubiertos, entre otros aspectos.

La tarea principal de la MD es el análisis automático o semi-automático de grandes cantidades de datos, para extraer patrones interesantes hasta ahora desconocidos, como también registros poco usuales (detección de anomalías) dependencias entre datos (minería por reglas de asociación), entre otros. Estos patrones pueden entonces ser vistos como una especie de resumen de los datos de entrada, y pueden ser utilizados en otros análisis adicionales, como por ejemplo, para hacer predicciones. Normalmente, la recolección de datos, la preparación de datos y la interpretación de los resultados, no forman parte de las etapas de un proceso de minería de datos, pertenecen a lo que se conoce como el proceso de descubrimiento de conocimiento (KDD, por sus siglas en inglés) [4].

Un proyecto de minería de datos tiene varias fases necesarias que son, esencialmente:

- **Comprensión:** del negocio y del problema que se quiere resolver.
- **Determinación, obtención y limpieza:** de los datos necesarios.
- **Creación de modelos matemáticos.**
- **Validación y comunicación:** de los resultados obtenidos.
- **Integración de los resultados en un sistema transaccional o de toma de decisiones.**

La relación entre todas estas fases sólo es lineal sobre el papel. En realidad, es mucho más compleja y esconde toda una jerarquía de subfases.

Por otro lado, las técnicas de Minería de Datos más comúnmente usadas son [6]:

- **Redes neuronales artificiales.** Modelos predecibles no lineales que aprenden a través del entrenamiento y semejan la estructura de una red neuronal biológica.
- **Árboles de decisión.** Estructuras de forma de árbol que representan conjunto de decisiones. Estas decisiones generan reglas para la clasificación de un conjuntos de datos. Métodos específicos de árboles de decisión incluyen árboles de clasificación y regresión (CART = Classification And Regression Tree) y detección de interacción automática de  $\chi^2$  cuadrado (CHAID = Chi Square Automatic Interaction Detection).
- **Algoritmos Genéticos.** Técnicas de optimización que usan procesos como combinaciones genéticas, mutaciones y selección natural en un diseño basado en los conceptos de evolución.
- **Método del vecino más cercano.** Una técnica que clasifica cada registro en un conjunto de datos basado en una combinación de las clases del/ de los K registro (s) más similar/es a él en un conjunto de datos históricos (donde  $k=1$ ). Algunas veces se llama la técnica del vecino k-más cercano.
- **Regla de inducción.** La extracción de reglas if-then de datos basados en significados estadísticos.

### III. MÉTODO DE LEVANTAMIENTO ARTIFICIAL POR BOMBA ELETROSUMERGIBLE

El método de levantamiento artificial por Bomba Electrosumergible (BES) tiene como principio fundamental extraer el fluido desde el fondo del pozo hacia la superficie, mediante rotación centrífuga de los impulsores de la bomba instalada en el subsuelo, que permite que el fluido multifásico ascienda a través de las etapas de los impulsores y llegue al cabezal del pozo con suficiente energía hasta la estación recolectora. La potencia requerida por la bomba electrosumergible es suministrada por un motor eléctrico acoplado al eje de la bomba, el cual está ubicado en el fondo del pozo. El suministro eléctrico del motor se logra a través de un cable de potencia fijado a la tubería de producción que a su vez soporta el sistema de fondo y conecta el motor a la superficie. Un equipo BES consta básicamente, de una bomba centrífuga de varias etapas, cuyo eje está conectado directamente a través de una sección protectora a un motor eléctrico sumergible. El cable se sujeta a la tubería mediante bandas metálicas flexibles colocadas cada 12 o 15 pies o mediante protectores de cable ubicados en cada una de las juntas de la completación. El conjunto motor-protector tiene un acoplamiento continuo que se logra mediante acoples estriados. La entrada del fluido a la bomba se efectúa a través de la sección de entrada o el separador de gas, dispuesto en la parte inferior de la bomba, tal como lo indica la Fig. 1.




Fig. 1. Diseño Esquemático de un Pozo Productor de Crudo por Bomba Electrosumergible

En tal sentido, para la implantación en campo de este método BES se requiere de un arreglo de instrumentación y control [7-8]. Para tal fin se requiere la medición y control de las siguientes variables.

- **A nivel de la Bomba,**
  - La presión de entrada a la bomba ( $P_{ip}$ ), para determinar la capacidad de levantamiento del pozo, calcular la tasa posible de producción, y construir la curva de afluencia o comportamiento del mismo.
  - Temperatura de Entrada a la Bomba ( $T_{ip}$ ), que permite diagnosticar el estado óptimo de temperatura de operación de la bomba. Un aumento en la temperatura del motor puede ser causada por un flujo deficiente, ya que el motor no se estará refrigerando adecuadamente.

- Presión de Descarga de la Bomba (Pdp), esta presión determina la capacidad de levantamiento de la bomba para desplazar el fluido hacia la superficie. Permite obtener la curva real de levantamiento de la bomba.
- La frecuencia de la Bomba, es una de las variables que revisten importancia vital a la hora de explotar el yacimiento de manera racional. Es por medio de ella que se logra realizar el control de la presión de entrada a la bomba (Pip).
- A nivel de la Superficie,
  - La Temperatura del Cabezal (Tc) permite detectar cambios bruscos o relativamente lentos en el comportamiento del pozo; que puede ser usado para anticiparse a los distintos regímenes de producción; incluyendo los incidentes que pudieran presentarse en la operación.
  - La Presión del Cabezal es un indicador de la cantidad de energía útil para hacer fluir el petróleo hasta la estación de recolección en la superficie.
- A nivel del Yacimiento,
  - La Presión y Temperatura de Fondo Fluyente, son medidas en el fondo del pozo, frente a la arena desde la cual se está produciendo, mientras el pozo está fluyendo.

#### IV. EXPERIMENTACIÓN CON EL SISTEMA BASADO EN MINERÍA DE DATOS

El sensor virtual busca inferir la temperatura de entrada a la bomba, para pozos por Levantamiento Artificial BES. Ese procedimiento se seguiría para cualquier pozo BES. La predicción de la temperatura de entrada a la bomba (en el subsuelo) se hará usando las variables eléctricas y del proceso en el subsuelo/superficie, para identificar estados operacionales. El desarrollo de esta herramienta permitirá al operador tomar previsiones, cuando alguno de los estados ocurra, y minimizar pérdidas en la producción al reducir posibles fallas en los equipos y en su operación.

La metodología utilizada para el desarrollo del sensor virtual es la CRISP-DM (Cross Industry Standard Process for Data Mining), ya que es una de las más ampliamente utilizadas en el ambiente académico e industrial [3]. A esa metodología se le han hecho ajustes, según lo propuesto en [1-2]. A continuación se desarrollan las seis (06) fases de la metodología ajustada, para el caso del Sensor Virtual.

##### A. Primera y Segunda Fase: Compresión del Negocio y Datos

En estas fases se realizó la compresión del funcionamiento del proceso, con el objetivo de generar el escenario futuro deseado y la tarea de minería de datos a realizar. En la segunda fase es preciso detectar las variables a usar desde las fuentes de datos (*vista minable conceptual*: subconjunto de datos sobre el que se va a aplicar una técnica de MD, también llamadas variables significativas). Además se determina las variables a calcular, a las cuales se le denominan variables objetivos, ya

que las mismas son las que se desean predecir, clasificar, calcular, inferir, en otras palabras, son las que deseamos obtener con la tarea de MD. Así, en esta fase se definen las variables objetivo del escenario futuro seleccionado. Determinar todas las variables de interés en la vista minable (variables objetivas y significativas), es el objetivo de este punto.

En nuestro caso, esas variables son las corrientes, frecuencia, presiones y temperatura, a lo largo del proceso de producción en el pozo. Así, se identificaron 10 variables.

##### B. Tercera Fase: Preparación de los Datos

Para aplicar MD sobre un problema en específico, es necesario contar con un historial de datos asociado al problema de estudio. Esto conlleva realizar distintas operaciones con los datos, con la finalidad de acondicionarlos para desarrollar un modelo de MD. Durante el desarrollo de ésta fase se crea la *vista minable operativa*, que básicamente el histórico de las variables. Así, la vista minable operativa consiste en un proceso de Extracción, Transformación y Limpieza de las variables, desde las bases de datos organizacionales.

Para ello, se usó un histórico de 6 meses, los cuales reflejan los escenarios presentes en el pozo durante dicho período. Esta etapa se centra en generar datos de calidad, es decir, datos sin anomalías, sin inconsistencias de formato, sin capturas erróneas, sin campos vacíos; aplicando métodos de limpieza, transformación y reducción (análisis de dependencias) sobre la vista minable conceptual.

Cabe destacar que ya existen muchas técnicas y algoritmos para realizar esta etapa (como lo es el análisis de correlación y el cálculo de la entropía).

Algunos de los resultados obtenidos fueron: se removieron los datos atípicos (por ejemplo: valores negativos de frecuencia y presiones, lapsos de datos sin muestreo en todos o algunos de los datos de interés, etc.). También, por las relaciones de dependencia entre las variables, se pasaron de 10 variables a 7 variables (alta relación lineal). Las variables originalmente recopiladas fueron:

- Corriente de Salida del Variador Fase A
- Corriente de Salida del Variador Fase B
- Corriente de Salida del Variador Fase C
- Corriente de fondo en el motor Fase A (eliminada)
- Corriente de fondo en el motor Fase B (eliminada)
- Corriente de fondo en el motor Fase C (eliminada)
- Presión en la línea de producción.
- Frecuencia del motor
- Presión de entrada a la bomba
- Temperatura de entrada a la bomba (a inferir).

Se escogieron estas variables debido a que el sistema de adquisición de datos (SCADA) posee almacenadas y disponibles estas señales del pozo bajo estudio.

##### C. Cuarta Fase: Modelado

Esta etapa tiene como finalidad escoger la técnica de MD para obtener el modelo de conocimiento resultante. Para ello, se desarrolló una tabla de comparación entre las técnicas

probadas, para conocer cual se adapta mejor a la estructura de los datos. Así, se debe definir el porcentaje de los datos de entrenamiento y de prueba en la vista minable operativa. Dependiendo de la técnica de MD a ser usada, varían esos porcentajes. Además, se deben definir las métricas a utilizar en la comparación.

En nuestro caso, se seleccionaron 4 técnicas que permiten inferir variables numéricas, estas son: regresión lineal, árboles de decisión, redes neuronales y método del vecino más cercano. Los indicadores utilizados en la comparación del desempeño de las técnicas utilizadas son: el error absoluto relativo (1), el error cuadrático relativo (2) y el coeficiente de correlación (3). En las Tablas I a IV se presentan los resultados obtenidos con cada técnica.

$$\frac{|p_1 - a_1| + \dots + |p_n - a_n|}{|a_1 - \bar{a}| + \dots + |a_n - \bar{a}|} \quad (1)$$

$$\sqrt{\frac{(p_1 - a_1)^2 + \dots + (p_n - a_n)^2}{(a_1 - \bar{a})^2 + \dots + (a_n - \bar{a})^2}} \quad (2)$$

$$\frac{n \sum x_i y_i - \sum x_i \sum y_i}{\sqrt{(n \sum x_i^2 - (\sum x_i)^2)(n \sum y_i^2 - (\sum y_i)^2)}} \quad (3)$$

Donde:

$$\bar{a} = \frac{1}{n} \sum_{i=1}^n a_i \quad (4)$$

TABLE I. REGRESIÓN LINEAL

Muestra	Indicadores		
	Raíz Error Cuadrático Relativo	Error Absoluto Relativo	Coficiente de correlación
1	3,5933	2,3900	0,8854
2	5,4824	2,4548	0,7559
3	3,4126	2,2347	0,8861
Todo	4,2103	2,3241	0,8460

TABLE II. PERCEPTRÓN MULTICAPA

Muestra	Indicadores		
	Raíz Error Cuadrático Relativo	Error Absoluto Relativo	Coficiente de correlación
1	3,3387	2,2350	0,9093
2	5,0566	2,1870	0,7969
3	2,9227	2,1494	0,9198
Todo	4,9575	3,0704	0,7949

TABLE III. ARBOL DE DECISIÓN

Muestra	Indicadores		
	Raíz Error Cuadrático Relativo	Error Absoluto Relativo	Coficiente de correlación
1	2,0987*	0,9693	0,9646
2	8,9384	1,2137	0,4619
3	1,8054*	0,9198	0,9696*

Muestra	Indicadores		
	Raíz Error Cuadrático Relativo	Error Absoluto Relativo	Coficiente de correlación
Todo	4,6118	0,9186	0,8263

TABLE IV. MÉTODO DEL VECINO MÁS CERCANO

Muestra	Indicadores		
	Raíz Error Cuadrático Relativo	Error Absoluto Relativo	Coficiente de correlación
1	2,0991	0,9100*	0,9655*
2	4,1434*	1,0244*	0,8688*
3	2,0591	0,8524*	0,9613
Todo	2,9059*	0,9097*	0,9304*

Cada una de las técnicas tuvo un tiempo diferente de ejecución durante el entrenamiento, siendo el algoritmo del vecino más cercano el más rápido, seguido por la regresión lineal, luego por el árbol de decisión de modelos y por último, el perceptron multicapa. Basándose en las Tablas I a IV, la técnica con menor error para la tarea de modelado del conjunto de datos es la técnica del vecino más cercano. Finalmente fueron creados los modelos definitivos con el 66,6% de los datos con las técnicas seleccionadas.

D. Quinta Fase: Evaluación

Los modelos generados en la fase anterior fueron probados con el 33,4% de los datos restantes, pero para efectos prácticos aquí se muestran solamente 16 instancias tomadas aleatoriamente. Los resultados arrojados por los modelos se muestran en la Tabla V:

TABLE V. RESULTADOS EVALUACIÓN DE MODELOS

Valor Real	Percep. Mult.		Reg. Lin.		Arb. Dec.		MVMC		
	Val. Inf	Dif (abs)	Val. Inf	Dif (abs)	Val. Inf	Dif (abs)	Val. Inf	Dif (abs)	Error
201	199,5	1,46	200,9	0,08	201,0	0,05	201	0	0,00
201	200,9	0,06	201,8	0,79	199,5	1,54	198	3	1,49
201	199,7	1,33	200,6	0,42	200,8	0,21	201	0	0,00
200	200,4	0,39	201,4	1,41	199,9	0,06	200	0	0,00
199	201,8	2,78	203,1	4,05	199,3	0,29	200	1	0,50
199	200,5	1,50	201,0	2,02	199,3	0,27	200	1	0,50
200	200,2	0,20	200,3	0,31	201,1	1,12	200	0	0,00
200	199,1	0,91	200,7	0,68	200,1	0,12	200	0	0,00
201	199,6	1,41	201,2	0,23	201,1	0,10	201	0	0,00
182	160,1	21,89	164,4	17,57	175,6	6,42	176	6	3,30
204	201,3	2,70	202,0	2,00	204,5	0,51	204	0	0,00
204	201,6	2,36	202,3	1,68	205,1	1,14	206	2	0,98
199	199,9	0,91	200,9	1,91	200,0	1,03	201	2	1,01
215	197,4	17,63	198,0	17,05	208,9	6,13	212	3	1,40
199	200,3	1,31	201,2	2,19	199,2	0,19	199	0	0,00
206	201,8	4,22	202,5	3,52	205,6	0,45	205	1	0,49
	prm	3,82	prm	3,49	prm	1,23	prm	1,19	0,60

Observando los resultados de los modelos evaluados, comparando con los valores reales de la temperatura de entrada de la bomba en °C mostrados en la Tabla V, se aprecia el

mejor desempeño con un promedio del error absoluto de 1,19 °C al modelo del Método del Vecino más Cercano, presentando la menor diferencia en la variable inferida con respecto al valor real, en este caso se repite el comportamiento calculado en la fase anterior. Ordenando de menor a mayor aproximación se tienen: el Perceptron Multicapa (PM), la Regresión Lineal (RL), el Árbol de Decisión (AD) y el Método del Vecino más Cercano (MVMC), por lo tanto se puede comprobar que éste último modelo infiere al valor real con un error cercano al 1%.

#### E. Sexta Fase: Implementación

En este trabajo, se utilizó para el desarrollo del modelo de conocimiento basado en técnicas de MD, a la herramienta WEKA (Waikato Environment for Knowledge Analysis).

Para la implementación del prototipo se usó NetBeans, que es un entorno de desarrollo integrado libre, hecho principalmente para el lenguaje de programación JAVA. Desde el prototipo se invocó los API (Application Programming Interface) que proporciona WEKA para conectarse con sus librerías de desarrollo y en la Fig. 2 se muestra un ejemplo del llamado a clases y métodos de WEKA.

```
1 import weka.core.Instances;
2 import java.io.BufferedReader;
3 import java.io.FileReader;
4 import weka.classifiers.Classifier;
5
6 public class PredictorIBk_003 {
7
8     public static void main(String[] args) throws Exception {
9
10        BufferedReader arch_prueba = new BufferedReader(new FileReader("/ruta/archi
11        Instances prueb = new Instances(arch_prueba);
12        prueb.setClassIndex(prueb.numAttributes() - 1);
13        Classifier model4 = (Classifier) weka.core.SerializationHelper.read("/ruta/t
14        System.out.println("\n=====");
15        System.out.println("real : pred");
16        for(int j = 0; j < prueb.numInstances(); j++) {
17            double label = model4.classifyInstance(prueb.instance(j));
18            System.out.println( (j+1) + ":\t" + prueb.instance(j).toString() + " ");
19        }
20    }
21 }
```

Fig. 2. Ejemplo de Implementación en JAVA

#### V. CONCLUSIONES

La propuesta de un Sistema de Predicción de la temperatura de entrada de la bomba para la optimización de la producción a Nivel del pozo, constituye un primer paso para la construcción de un mecanismo de observación, recolección de datos y su interpretación a nivel del pozo, dotando de información al controlador del proceso. Dicha inteligencia es entendida como la capacidad del Pozo para auto-organizarse, según sus condiciones y la de su entorno. Este enfoque supera al enfoque clásico de los Sistemas de Control y Adquisición de Datos (SCADA = Supervisory Control And Data Acquisition), que se

limitan a tareas de supervisión y control, a partir de la siguiente idea: está basado en un proceso de auto-regulación en Pozo, a partir de la información que ellos manejan, lo que les permite anticipar situaciones, tener un comportamiento proactivo, sin perder la visión global del negocio. En ese sentido, nuestro enfoque es autónomo y distribuido.

El sistema de predicción desarrollado, fue capaz de inferir la temperatura de entrada de la bomba (TIP) a través de las variables determinadas en la vista minable operativa, permitiendo al operador de una sala de control identificar escenarios operacionales ante la ausencia del sensor físico como tal, mejorando el conocimiento sobre el proceso de extracción al mantener la tasa de flujo de producción a un menor costo. Por otro lado, con éste trabajo se demuestra que la MD es aplicable al campo petrolero y contribuye con aportes significativos en cuanto a la inferencia de variables claves y difíciles de medir.

#### REFERENCIAS

- [1] J. Aguilar, et al. "Metodología para identificar tareas de minería de datos en una organización. Informe Técnico", CEMISID. Universidad de los Andes. 2013.
- [2] C. Rangel, et al. "Methodology for detecting the feasibility of using data mining in an organization", Proceedings of the XXXIX Conferencia Latinoamericana en Informática (CLEI 2013), IEEE Xplore, Vol.1, pp. 502-513, Naiguatá, Venezuela, Octubre 2013.
- [3] R. Keith "Oilfield Data Mining Workflows for Robust Reservoir Characterization". Society of Petroleum Engineers. SPE 149785. March 2012.
- [4] J. Gallardo. "Metodología para la Definición de Requisitos en Proyectos de Data Mining (ER-DM)", Universidad Politécnica de Madrid, 2009.
- [5] A. Sharma "Classification of Oil and Gas Reservoirs Based on Recovery Factor: A Data Mining Approach". Society of Petroleum Engineers. SPE 130257. Septiembre 2010.
- [6] E. Aceros, E. Camargo "Sistema Inteligente de Producción Industrial Para Estaciones de Flujo, Proceedings of the VI Congreso Iberoamericano de Estudiantes de Ingeniería Eléctrica (VI CIBELEC 2015)", ISBN: 978-980-7185-03-5, pp. CA 14-19, Mérida, Venezuela, Mayo 2015.
- [7] E. Camargo, E. Aceros, J. Aguilar; "Intelligent Well Systems" 2015 Asia-Pacific Conference on Computer Aided System Engineering, pp13-18, Julio 2015.
- [8] E. Aceros, E. Camargo, O. Parabavire; "Comparación Cualitativa del Desempeño de la Aplicación del Control Predictivo Basado en Modelo (CPBM) y el PID para el Control de Nivel en Pozos", Proceedings of the IV Simposio Científico y Tecnológico en Computación / SCTC 2016, ISBN: 978-980-12-8407-9, pp. 88-94, Universidad Central de Venezuela, Caracas, Venezuela, Mayo 2016.