Optimización de la Probabilidad de Falla en el Proceso de Evaluación de Integridad de Ductos para el Transporte de Hidrocarburos por Medio de Algoritmos Genéticos

Probability of Failure Optimization in the Oil Transportation Pipeline Integrity Assessment Process using Genetic Algorithms

Gustavo Calzada-Orihuela [1], Gustavo Urquiza-Beltrán [1], Jorge A Ascencio-Gutiérrez [2], Gerardo Reyes-Salgado [3]
[1]Centro de Investigación en Ingeniería y Ciencias Aplicadas, Universidad Autónoma del Estado de Morelos, Av. Universidad No. 1001, Col Chamilpa, Cuernavaca, Morelos, C. P. 62209
[2] Universidad Politécnica de Quintana Roo, Av. Arco Bicentenario, Mza. 11, Lote 1119-33, Sm. 255. Cancún, Quintana Roo, México. C.P. 77500
[3] Departamento de Ciencias Computacionales, Centro Nacional de Investigación y Desarrollo Tecnológico CENIDET, Interior Internado Palmira S/N, Col. Palmira, Cuernavaca, Morelos, C.P. 62490
gustavocalzada@gmail.com, gurquiza@uaem.mx, jascenciogtz@gmail.com, greyes@cenidet.edu.mx

PALABRAS CLAVE:

Algoritmos Genéticos, Evaluación de Integridad, Evaluación de Riesgo, Integridad de Ductos, Optimización, Sistema de Soporte de Decisiones.

RESUMEN

La industria del petróleo es una de las más prolíferas alrededor del mundo. Nuestra vida diaria está rodeada del petróleo, desde el combustible en la mayoría de los sistemas de trasporte y los sistemas de producción de electricidad, hasta las miles de envolturas de productos que consumimos en el supermercado. La economía mundial está vinculada estrechamente al descubrimiento, extracción, explotación y trasformación del petróleo. Para llevar a cabo estos procesos, es necesario que el petróleo y sus productos sean trasportados de un punto a otro. El sistema de distribución más popular y seguro en la actualidad es el de tuberías o ductos instalados a través de varios o miles de kilómetros en tierra o mar. Sin embargo la naturaleza misma de este producto posee un riesgo latente en su manejo en todo momento. Por esta razón, organizaciones privadas y públicas, universidades, centros de investigación y gobiernos buscan constantemente colaborar para innovar y desarrollar metodologías y tecnologías que asistan las diferentes facetas de la producción, proceso y trasporte del petróleo con el fin de reducir las incidencias e impactos que tienen las fallas de los ductos que trasportan los hidrocarburos. En este trabajo se describe el desarrollo de un Sistema de Soporte de Decisiones inteligente para asistir al proceso de toma de decisiones construido con un conjunto de Algoritmos Genéticos que proveen configuraciones optimizadas de las variables que describen, de forma cuantitativa, la condición del ducto y la probabilidad de que deje de operar correctamente a causa de una o varias fallas. El propósito de este proyecto es encontrar soluciones que minimicen y optimicen el valor de la Probabilidad de Falla en un segmento de ducto y de esta forma, contribuir a la asignación optimizada de recursos para evitar incidentes que impacten en el medio ambiente o en la sociedad.

KEYWORDS:

Decision Support System, Genetic Algorithms, Integrity Assessment, Optimization, Pipeline Integrity, Probability of Failure, Risk Assessment, Risk Optimization, Transportation Logistics for Oil and Gas.

ABSTRACT

The Oil Industry is one of the most proliferous worldwide. We use the oil in most aspects of our daily life. Most transport systems and power plants commonly uses oil based fuel to operate. Global economy is closely linked to the oil exploration, extraction and transformation. In order to make this possible, it is essential to transport oil and its products from one point to another. Nowadays, the most popular and safest oil distribution systems are the pipelines, which are installed throughout several or even thousands of miles along the land and sea. Nevertheless, the oil industry possess implicitly a dangerous nature, a latent risk during its operations. That risk is a combination of the likelihood of an event to develop a pipeline failure and the likely impact on the environment, business and society. This is the reason why public and private organizations, universities, research centers and governments are continuously collaborating to innovate and develop methods and technologies to assist different production, process and transport stages in order to reduce or minimize incidents and pipeline failures. In this paper we describe the development of a smart Decision Support System to assist the Decision making process based on a set of Genetic Algorithms that provide optimized configurations of the variables, used to quantitatively describe the pipeline's condition and the Probability of Failure (PoF) under those conditions. Our project's purpose is to find solutions through a AI based system and a Pipeline Integrity Assessment methodology, to optimize and ultimately, minimize the PoF value associated to a pipeline segment in order to avoid pipeline failures and contribute to reduce incidents that impact on the environment and human life.

Recibido: 30 de julio del 2017 • Aceptado: 28 de octubre del 2017 • Publicado en línea: 28 de febrero del 2018

1. INTRODUCCION

El petróleo ha sido usado desde hace miles de años. Éste se usaba desde tiempos remotos principalmente como combustible, calefacción y fuente de iluminación, aunque también hay evidencia de que se usó con propósitos militares (Érij, 1988). No obstante, la industria petrolera ha sufrido cambios comerciales, tecnológicos y metodológicos importantes. En los últimos años ha sido evidente que la industria del petróleo se ha convertido en una de las más grandes y de mayor impacto en la economía internacional.

México es un país considerado como uno de los países más ricos del planeta gracias a que tiene una gran cantidad y diversidad de recursos naturales y uno de los recursos más importantes es la cantidad abundante de petróleo que se ha extraído a través de los años (Torres, 2002). Sin embargo, la importancia de la industria del petróleo se deriva no sólo de su participación en el producto interno bruto de algún país, sino de la influencia directa que tiene sobre cualquier actividad de la vida moderna a través de sus diversas cadenas productivas, como por ejemplo, gran parte de la energía que consumimos todos los días proviene o está relacionada con el uso del petróleo, por lo que sin él, muchas de las actividades que consideramos comunes, no serían posibles. Por esta razón, se considera importante construir métodos y herramientas modernas para asistir a la industria.

De acuerdo a (Chow, 1987), el petróleo crudo no es el único con el cual se puede generar riqueza, también se puede procesar para producir subproductos con mayor valor agregado en las Refinerías. Pero para que el petróleo pueda transformarse, primero se tiene que trasportar desde el punto de extracción hasta las donde se desee. Para esto se utilizan diferentes métodos que se engloban dentro de la Logística para el Trasporte y Distribución de Hidrocarburos (LTDH). Todo sistema para el trasporte de hidrocarburos corre el riesgo de sufrir una falla. Mulhbauer (2006) define este Riesgo como una combinación entre la Probabilidad de Falla (PoF) y la Consecuencia de Falla (CoF).

PoF se define de forma general como qué tan probable se considera que el sistema pudiera ser afectado por un mecanismo o amenaza en cierto tiempo que generara una falla. CoF, por otro lado, describe el impacto que pudiera tener una falla en caso de que sucediera. Es decir, que el Riesgo de Falla (RoF) está en función de bases fundamentales. Primero, la probabilidad de que una o varias amenazas afecten un segmento de ducto a tal grado sufra daño y falle Segundo, el impacto estimado que se generaría en caso de que un segmento de ducto falle. Por ejemplo, el Riesgo de Falla en un segmento de ducto se considera "alto" ya que se calcula que, bajo las condiciones actuales en las que opera el ducto, es muy probable que falle debido a un factor de agrietamiento intensificado por el número de oscilaciones a las que se expone el ducto todos los días. Además, este Riesgo se considera importante porque el segmento se encuentra en una zona urbana, lo que significa que en caso de explosión, cientos de personas y edificaciones sufrirían las consecuencias.

Debido a este tipo de escenarios, las organizaciones encargadas o responsables del trasporte de hidrocarburos continuamente están desarrollando investigación para crear metodologías y tecnologías que asistan al proceso de toma de decisiones para evitar incidentes y reducir lo más posible las afectaciones generadas por las fallas en los sistemas de ductos. Esta es la razón que motivó al Centro de Investigación en Ingeniería y Ciencias Aplicadas (CIICAP) de la Universidad Autónoma del Estado de Morelos (UAEM), con la colaboración del Instituto de Ciencias Físicas (ICF) de la Universidad Nacional Autónoma de México (UNAM) y el apoyo del Consejo Nacional de Ciencia y Tecnología (CONACYT), para desarrollar un Sistema de Soporte de Decisiones (DSS) basado en una Inteligencia Artificial a través del desarrollo de un conjunto Algoritmos Genéticos para asistir al proceso de toma de decisiones proveyendo configuraciones optimizadas para la reducción o minimización de la Probabilidad de Falla para un segmento de ducto, con la finalidad de ayudar a reducir el número de incidentes o fallas.

2. LOGÍSTICA PARA EL TRANSPORTE Y DISTRIBUCIÓN DE HIDROCARBUROS

De acuerdo a (Canto, 2016), un sistema de transporte de hidrocarburos es un sistema que distribuye petróleo y sus subproductos desde los pozos de extracción hasta el o los puntos destino donde será consumido o procesado. Las distancias y condiciones entre los puntos de producción y procesamiento químico hacen que los métodos de distribución varíen dependiendo de la

geografía, las necesidades de la empresa, del objetivo del producto, permisos y políticas, entre otros factores. Y aunque existen varios medios para el trasporte de petróleo, como tuberías, vagones-cisterna o en buques-cisterna, el uso de los sistemas de ductos es el método más económico y más usado en la actualidad.

Hoy en día, el trasporte de hidrocarburos se ha convertido en un proceso complejo que requiere de un análisis, una planificación y una evaluación constante. Y debido a su complejidad, la industria petrolífera ha invertido un gran esfuerzo y recursos para proveer de metodologías y herramientas a las áreas y personal responsable para facilitar sus actividades y mejorar los resultados en la planificación y métodos de trasporte. Por lo que en la actualidad, los sistemas computacionales han adquirido un gran valor en esta área, a través del procesamiento de datos para generar conocimiento (Kasemsap, 2016). Como por ejemplo, la Inteligencia de Negocios (BI) que evidencia el poder computacional para generar valor a la información y crear ventajas competitivas tanto a nivel operacional como negocio e incluso en el ámbito científico.

3. EVALUACIÓN DE INTEGRIDAD DE DUCTOS

En México y el mundo, el uso de tuberías es un método muy popular para el trasporte de petróleo y otros de sus subproductos a través de grandes distancias y distintos tipos de regiones geográficas. De acuerdo a (Cosham, 2003), la aceptación del uso de ductos se debe la buena reputación histórica que tiene este cuando es comparado con las estadísticas de otros medios, como el terrestre o marítimo. Sin embargo, es evidente que los ductos no son perfectos y que pueden fallar. Y a pesar de que el uso de los ductos se considera el más medio más confiable en la actualidad (Hopkins, 2009), el proceso de trasporte posee en sí un riesgo inherente debido a la naturaleza de los materiales altamente peligrosos que pueden generar grandes daños al medio ambiente, estructuras urbanas o rurales y a la vida misma. El objetivo de los modelos para evaluar la Integridad de Ductos es relacionar las condiciones de un segmento Ducto para estimar un valor de Riesgo por medio de la estimación del grado de Probabilidad de Falla.

La Norma Oficial Mexicana (NOM027, 2010), que dictamina los estándares y regulaciones para los procedimientos de evaluación de Riesgo de los ductos terrestres y marinos para el transporte de hidrocarburos, define al Riesgo como "una combinación de la probabilidad de que ocurra un evento y su consecuencia". En el trabajo de Muhlbauer (2006), el Riesgo se define como "un comportamiento teorizado del ducto durante un tiempo". Esto significa que, utilizando metodologías y datos, se crean modelos para describir el comportamiento del ducto con la finalidad de predecir futuros incidentes.

De forma general (Cosham, 2003; Muhlbauer, 2006; NOM027, 2010), el Riesgo puede entonces conceptualizarse en función del producto de la Probabilidad de Falla (PoF) por la Consecuencia de Falla (CoF), como se muestra en la siguiente ecuación:

Riesgo de Falla=(Probabilidad de Falla)(Consecuencia de Falla)

La Probabilidad de Falla es definida comúnmente como el "grado de creencia" de que un evento ocurra en un tiempo determinado, una combinación estadística basada en la relación de múltiples variables denominadas como amenazas que nos dan información de la posibilidad de que un segmento de ducto sufra un daño o, debido a la acción directa o indirecta de una o varias amenazas, deje de operar normalmente. Estas amenazas están clasificadas en dos categorías de acuerdo a la NOM027, las dependientes del tiempo y las independientes del tiempo, como se muestra en la Tabla 1.

Tabla 1. Clasificación de amenazas de acuerdo a su dependencia en el tiempo.

Mecanismo de Falla	Tipo de mecanismo
Independientes en el tiempo	Terceras partes Peligros terrestres Error humano Sabotaje Robo
Dependiente en el tiempo	Corrosión externa Corrosión interna Fatiga Agrietamiento por corrosión bajo tensión

La Consecuencia de Falla es definida por (Muhlbauer, 2006) como la "magnitud de impacto sobre los efectos de una falla" y está asociada a la pérdida de algún tipo como resultado del efecto que tiene una falla, por ejemplo, el número de edificios urbanos afectados por una explosión de un ducto que trasporta gas, el número de hectáreas afectadas por una fuga de combustible o crudo, el número de fatalidades en caso de siniestro, entre otras. Generalmente, la consecuencia se categoriza en tres impactos: Al medio ambiente, a la Población y al Negocio. En la Tabla 2 se muestra la clasificación de los

impactos.

Tabla 2. Clasificación de los Impactos asociados a CoF

Costos directos	Costos indirectos
Daños a propiedad	Litigación
Daños a la salud	Violaciones de contrato
Daños al medio ambiente	Insatisfacción del cliente
Pérdida de producto	Reacciones políticas
Costo de reparación	Pérdida de acciones en el mercado
Costo de limpieza	Multas gubernamentales

La complejidad de estos modelos puede variar dependiendo de las necesidades de la organización o quién esté realizando la evaluación. La forma más básica es una comparación lógica entre dos valores que producen una respuesta cualitativa, por ejemplo "Alto riesgo" o "Bajo riesgo". Sin embargo, los modelos pueden ser tan complejos como lógica difusa, módulos de Inteligencia Artificial o Sistemas expertos.

3.1. Proceso de Evaluación de Integridad de Ductos

Es un proceso de medición de ambos, Probabilidad y Consecuencia de todos los eventos potenciales que promueven una o varias amenazas relacionadas con los ductos para transporte de hidrocarburos. La evaluación de riesgo nos permite tomar decisiones para administrar el riesgo de esas amenazas.

El proceso de evaluación de integridad de ductos depende del juicio ingenieril del equipo responsable. Y aunque no existe un método universal para evaluar la integridad de los ductos el trabajo de Muhlbauer (2006), propone de forma general una serie de fases para evaluar y administrar el riesgo:

1. Modelo de Riesgo. El modelo es el conjunto de reglas que representa el comportamiento del Riesgo, es decir que es el conjunto de ecuaciones con el que se puede calcular y modelar el comportamiento del ducto.
2. Colección y preparación de Datos. Proceso en el que se reúne todos los datos disponibles del ducto que satisfagan todas y cada una de las entradas del Modelo de Riesgo, teniendo en cuenta sus formatos y reglas.
3. Segmentación lógica del ducto. Considerando que el ducto no es completamente uniforme en toda su longitud, se realiza una segmentación organizada del mismo dependiendo de los datos reunidos en la fase anterior.
4. Evaluación de Riesgo por segmento. Es el proceso por medio del cual se ejecuta o aplica el Modelo de Riesgo, alimentado por los datos colectados por cada segmento. El resultado de esta fase es un valor de riesgo asignado a cada segmento de todo el ducto estudiado.
5. Administración de Riesgo. Es el proceso por medio del cual se estudian los valores de Riesgo generadas y las condiciones que producen esos valores con el fin de proveer información para encontrar los medios óptimos para minimizar el Riesgo en uno o varios segmentos del ducto.

Esta última fase requiere de usuarios expertos para analizar los datos y tomar decisiones con el fin de reducir o minimizar el Riesgo del segmento de ducto expuesto a una o múltiples amenazas (Hopkins, 2000). Esta actividad es fundamental para el proceso de toma de decisiones de la organización. El objetivo de este proyecto es proponer una Inteligencia Artificial basada en Algoritmos Genéticos para proveer soporte inteligente al proceso de Administración e Riesgo con el fin de colaborar en la minimización del Riesgo.

4. ALGORITMOS GENÉTICOS

De acuerdo a (Russell, 1996), los Algoritmos Genéticos (AGs) son una rama de la Inteligencia Artificial (IA) compuesta por una familia de modelos computacionales basados en la evolución de los seres vivos. Es decir que los AGs son sistemas computacionales que están estructurados de alguna forma particular para representar en porciones delimitadas un problema. Estas estructuras se les conocen como "Cromosomas", que son la descripción fundamental del problema que más adelante se describe como individuo.

Para que los cromosomas pueden ser utilizados por los AGs, es necesario que sean codificados. En esta fase, el diseñador del AG selecciona, en base a su juicio ingenieril, el tipo de representación o código en el que se desean tratar los cromosomas. Aunque la codificación más común es el código binario (Coello, 2014), también puede utilizarse el código binario de Grey o la representación real.

En la naturaleza, cada individuo es un ejemplar de un organismo que está compuesto por un conjunto de cromosomas y cada cromosoma está a su vez formado por un conjunto de genes. Esta configuración genética es

el conjunto de "reglas" que dictaminan las características generales y específicas de cada individuo. Por ejemplo, en caso de los humanos, cierta configuración genética puede producir ojos de color marrón o verdes, otra configuración puede producir tez color negra o morena, rasgos fisonómicos, entre otras. Sin embargo, los genes no sólo contienen la información del aspecto físico de los organismos, sino también el comportamiento de cada célula y sus funciones básicas.

De acuerdo a la Teoría de la Evolución, los organismos y sus características están íntimamente relacionadas con el ambiente en el que se desarrollan (Coello, 2014). Esto quiere decir que por ejemplo, una tortuga marina, o mejor dicho, una tortuga adaptada a través del tiempo para vivir en un ambiente marino, no será tan eficaz en un ambiente completamente terrestre. Así mismo, una tortuga adaptada a vivir en un ambiente completamente terrestre, no será tan eficaz en un ambiente marino. Cada organismo está adaptado para sobrevivir en el ambiente en el que vive y de acuerdo a la Evolución, estos organismos están continuamente evolucionando o modificándose para ser más eficientes. De la misma forma, los Algoritmos Genéticos simulan la estructura de un organismo, denominado como individuo, constituido por un cromosoma que a su vez está compuesto por un conjunto de genes que generan un valor de desempeño en un ambiente dado.

Dentro de un proceso evolutivo, los seres vivos sufren una adaptación genética al medio ambiente al que están expuestos para sobrevivir. En el caso de los AGs, este ambiente se mide por medio de una Función de Aptitud, que es un modelo matemático que mide la efectividad de la combinación de las variables.

Las interacciones de los cromosomas proponen posibles soluciones a un problema determinado por medio de la combinación y modificación de los genes o características del modelo del problema, preservando las soluciones con mejor desempeño a través del tiempo para finalmente generar un conjunto de soluciones óptimas para el problema. Estas combinaciones y modificaciones se conocen como operadores de Cruza y Mutación.

4.1. Entidades de los Algoritmos Genéticos

Los AGs normalmente son implementados por fases. De acuerdo a (Coello, 2014; Russel, 1996) la primera etapa es el análisis del problema, en donde estudia el problema. Esto tiene como resultado la construcción del cromosoma a partir de las variables participantes, codificadas en genes. La siguiente fase es seleccionar una codificación definida, es decir, una representación de forma completa los valores o rangos de valores que tiene cada una de las variables que conforman el cromosoma (Dandy, 1996). Una vez que se ha definido el cromosoma y su representación, la fase siguiente es la determinación de las técnicas de Cruza y Mutación.

De acuerdo a (Coello, 2014) existen varias técnicas de cruza y cada una tiene sus propias características, como la Cruza Simple, de Dos puntos, Uniforme, Intermedia, entre otras. Además existen también múltiples técnicas de mutación como la Mutación por Inserción, Heurística, por Intercambio, Uniforme, No uniforme, entre otras. Mientras que para la generación de soluciones y comparar los resultados se define la Ecuación o Ecuaciones de Aptitud para poder medir la efectividad de la solución que se genera cada cromosoma.

Por último, cuando se ha construido el cromosoma y diseñado su representación, se tiene que seleccionar los parámetros que se utilizarán para la ejecución del GA, tales como el número de individuos a utilizar, número de generaciones durante el proceso, la probabilidad de cruza y el porcentaje de mutación. Éstos últimos sirven principalmente para determinar qué tan probable es que se genere una mutación en una generación y qué tan probable es que un gen de un padre pase a la siguiente generación por medio de sus hijos.

4.2. Proceso de los Algoritmos Genéticos

Para que un organismo se adapte al ambiente a su alrededor en la naturaleza, necesita de varias generaciones, combinaciones genéticas por medio de la cruza, selección natural y en ocasiones también mutación. Los AGs, basados en el proceso natural evolutivo, también requieren de los componentes anteriores. El proceso de los AGs comienza con la generación aleatoria de genes de "n" cromosomas que conforma a un individuo cada uno, donde "n" representa el número de individuos que se generarán por cada generación. Es importante que los genes de los cromosomas respeten los límites de operación de cada variable que representan, de otra forma, se generarán resultados poco reales y de poca utilidad. La intención de la primera generación de individuos es insertar valores aleatorios en los genes de

cada cromosoma para abarcar el mayor espectro posible de valores con la finalidad de experimentar y buscar las combinaciones más óptimas.

Cuando se crea la primera generación, estos individuos se les consideran como "Padres" ya que son los primeros individuos del proceso. El siguiente paso es generar individuos denominados como "Hijos", que son el resultado de la operación de Cruza. Generalmente la Cruza requiere dos individuos Padres (Padre A y Padre B) para generar dos individuos Hijos (Hijo A e Hijo B). La forma en cómo se van a combinar los genes depende del método de Cruza seleccionado. Primero se toma una parte de los genes del Padre A y otra parte de los genes del Padre B para generar a un Hijo A. Después se hace el mismo proceso pero en diferente orden para generar el Hijo B. Posteriormente se toman los siguientes dos individuos Padres para generar un segundo par de individuos Hijos. Se continúa con el proceso de forma iterativa hasta terminar cruzar los "n" Padres y generar "n" Hijos. Tanto los cromosomas de los Padres como los de los Hijos se deben almacenar en alguna estructura de datos para ser utilizados posteriormente.

El siguiente paso es insertar los cromosomas de cada individuo Padre y cada individuo Hijo en la Función de Aptitud. El resultado de este proceso es obtener un valor cuantitativo que permita evaluar o medir el desempeño que tiene cada individuo. Cada solución generada por un Padre o un Hijo también debe de ser almacenada para poder continuar con el proceso de Selección. Este proceso tiene el objetivo de comparar las soluciones de los individuos Padres contra las soluciones producidas por los individuos Hijos. Es decir que si la solución del Padre A es más óptima que la solución del Hijo A, el Padre A es seleccionado para continuar en la siguiente generación, pero si el Hijo A genera una solución más óptima que el Padre A, entonces el Hijo A es seleccionado para continuar en la siguiente generación sustituyendo al Padre A. De esta forma se seleccionan los "n" mejores individuos de la generación y se convierten en los Padres de la nueva generación. Estos procesos se repiten por el número de generaciones determinadas antes de la ejecución del Algoritmo Genético. La última generación se espera que contenga el conjunto de individuos cuyas soluciones son las más óptimas, sin embargo, dado que los AGs trabajan de forma heurística, no se puede garantizar que dentro de los individuos se encuentra la mejor combinación, sino un conjunto de combinaciones optimizadas (Coello, 2014; Russell, 1996).

En cualquier industria, incluyendo la petrolera, cuando se está buscando una configuración optimizada de un problema, tal vez el reto principal sea la identificación de las características o genes que representan tal problema, así como la Función de Aptitud que se utilizará para medir el éxito de las soluciones. Para el proyecto, los genes son las variables asociadas al proceso de Evaluación de Integridad de Ductos y las Funciones de Aptitud son el mismo Algoritmo para la Evaluación de Integridad de Ductos, descompuesto por el cálculo de la Probabilidad de Falla por amenaza. De esta forma, el resultado de los Algoritmos Genéticos para este proyecto es un conjunto de configuraciones de las variables del ducto para minimizar o reducir la Probabilidad de Falla. El resultado de este proyecto se espera que impacte directamente en el proceso de toma de decisiones en la fase de Administración de Riesgo, dando soporte a los expertos del área para formular estrategias inteligentes y finalmente evitar futuros siniestros.

5. ALGORITMOS GENÉTICOS PARA ASISTIR AL PROCESO DE EVALUACIÓN DE INTEGRIDAD

Actualmente la industria petrolera es una de las más importantes gracias a su vínculo a la economía mundial. Sin embargo, la naturaleza de su operación trae consigo un riesgo latente para el medio ambiente y la sociedad. De ahí la importancia de que el personal experto y equipos responsables tengan las herramientas y la información para identificar y prevenir de forma oportuna y precisa las posibles fallas en los sistemas de ductos para el trasporte de hidrocarburos. Este proyecto es un esfuerzo para proveer un Sistema para el Soporte de Decisiones (DSS) basado en una Inteligencia Artificial de bajo costo para identificar configuraciones óptimas para la reducción del valor de Riesgo y asistir al personal experto a tomar decisiones.

El Algoritmo Genético propuesto en este proyecto consiste en la ejecución de las siguientes actividades:

1. Selección de algoritmo de evaluación de riesgo. El proyecto utiliza un modelo probabilístico (Muhlbauer, 2006) para la Evaluación de Integridad de Ductos, adaptado dar cumplimiento a la Norma Oficial Mexicana (NOM027, 2010; Ramírez, 2014).
2. Análisis del Algoritmo de Evaluación de Riesgo.
3. Clasificación de entidades. En esta actividad, las

entidades participantes en el Algoritmo se describen por su nombre, tipo de dato, rango de valores por defecto, representación en el AG, además se determina si es un dato representa una entrada o calculo.

4. Codificación de variables en genes y cromosomas.
5. Análisis y selección de Funciones de Aptitud.
6. Análisis y selección de operadores de Cruza y Mutación.
7. Selección de parámetros de Cruza y Mutación.
8. Selección y población de primera generación de individuos.
9. Cruza y mutación de individuos
10. Generación de individuos Hijos
11. Selección de mejores Individuos.
12. Diseño y ejecución de pruebas.

5.1. Representación del Problema

Una de las fases más importantes para el desarrollo e implementación de un Algoritmo Genético es la Representación del Problema. Para este proyecto, los genes de los cromosomas se generaron a partir del modelo de evaluación de integridad. Para ello se clasificaron sus subelementos y variables con el fin de identificar su función dentro del algoritmo y sus rangos aproximados operacionales. La identificación de los rangos es importante porque en la práctica, si los genes no respetan sus rangos operacionales, los resultados pueden ser irreales o con poca aplicación. Por ejemplo, no es viable para la operación del ducto reducir por completo la presión o el flujo, ya que aunque minimiza la Probabilidad de Falla, no representa una solución real.

El proyecto utiliza seis cromosomas. Cada cromosoma corresponde a cada amenaza identificada en el algoritmo, que son: Terceras Partes o Daño Mecánico, Operaciones Incorrectas, Sabotaje y Robo, Peligros Terrestres, Corrosión Interna y Agrietamiento por Corrosión. Las variables de cada cromosoma fueron clasificadas en tres sub categorías: Fijas, Calculadas y Variables. La diferencia entre ellas es que las variables Fijas representan características del ducto que pueden cambiar a lo largo del ducto pero que no pueden ser modificadas libremente por el AG debido a que es irreal y poco práctico, por ejemplo el tipo de producto que trasporta, el espesor real del ducto o fecha de fabricación. Las propiedades Calculadas son aquellas que varían a lo largo de la extensión del ducto pero son el resultado del proceso de otras variables, por lo que no pueden ser parte del cromosoma ya que no pueden modificarse sus valores voluntariamente ni de forma aleatoria, sino que tienen que ser el resultado del comportamiento de las demás variables. Por último las características denominadas como Variables son aquellas que si pueden ser modificadas por el AG y son las que conforman los genes de los cromosomas para cada amenaza, por ejemplo, la presencia de protección catódica, la presencia de patrullaje o si el ducto posee recubrimiento. El objetivo del AG es explorar los valores de las Variables para encontrar una configuración óptima para la reducción de la Probabilidad de Falla de un segmento de ducto.

Para codificar los genes, en el proyecto utilizamos la representación real en vez de la codificación binaria. Esto se debe a que los valores del dominio del proceso de Evaluación de la Integridad de Ductos son muy amplios por la precisión decimal que requiere. Aunque algunos de los valores pueden ser enteros y limitados, después de un análisis, se concluyó que la representación real es la opción más óptima.

5.2. Funciones de Aptitud

Como se mencionó en la Sección 4, las Funciones de Aptitud sirven para medir cuantitativamente el desempeño de los cromosomas. Cada cromosoma debe ser evaluado por su propia Función de Aptitud, por lo que en este trabajo se utilizaron seis Funciones de Aptitud diferentes, una por cada amenaza evaluada.

El resultado de las Funciones de Aptitud que se utilizaron genera un valor porcentual de la Probabilidad de Falla. Por lo tanto, de acuerdo al trabajo (Mulhbauer, 2006), cada ecuación están en función de tres términos generales: La Probabilidad del Daño, la Exposición del Ducto y la Resistencia, que para este caso práctico, son propiedades Calculadas.

5.3. Proceso de Cruza de Individuos

El proceso de Cruza toma los genes de dos individuos Padre y los combina para generar dos individuos Hijo. Cada Hijo contiene información "genética" de cada uno de los dos Padres.

Aunque existen diversos métodos de cruza, decidimos usar la "Cruza Intermedia" para este proyecto. Esta técnica consiste en combinar una parte del Padre X

con una parte del Padre Y, usando una posición k como delimitador entre los genes de uno y otro (Coello, 2014) como se describe en la Tabla 3.

Tabla 3. Tabla descriptiva del mecanismo de Cruza Intermedia

Padre X $= (x_1, x_2, x_3, \ldots, x_n)$ *Padre Y* $= (y_1, y_2, y_3, \ldots, y_n)$	*Hijo X* $= (x_1, \ldots, x_k, y_{k+1} * a + x_{k+1} * (1 - a), y_m * a + x_m * (1 - a))$ *Hijo Y* $= (y_1, \ldots, y_k, x_{k+1} * a + y_{k+1} * (1 - a), x_m * a + y_m * (1 - a))$	Donde: ***k*** es la posición intermedia del número total de genes de cada cromosoma. ***a*** es un factor de ponderación aleatorio entre 0 y 1.

5.4. Mutación de Individuos

En la naturaleza, la Mutación es un proceso donde un gen o genes del cromosoma son alterados o se modifican inesperadamente. Esta alteración no es el resultado de la Cruza o de la combinación genética, sino una modificación enteramente aleatoria. En los organismos, la Mutación puede tener un espectro muy amplio como resultado. Los organismos que sufren una mutación pueden tener "saltos evolutivos" y desarrollar una mejor adaptación y desempeño hacia el ambiente que le rodea y por medio de la Cruza, el organismo mutado puede producir Hijos con capacidades mejoradas en las siguientes generaciones. Sin embargo, puede ocurrir completamente lo contrario, un organismo mutado puede generar un desempeño muy pobre y no desarrollar una ventaja en su medio ambiente, por lo que sería descartado de acuerdo a la Selección Natural.

En términos de los Algoritmos Genéticos, la Mutación es un operador que explora soluciones que pueden ser inaccesibles en el dominio local, lo que lo convierte en un factor importante en la exploración de soluciones óptimas a un problema. Este proceso requiere que se escoja aleatoriamente un gen de un cromosoma seleccionado. Este gen es modificado de forma deliberada pero su valor se modifica generalmente al azar. La Mutación no ocurre en todas las generaciones ya que depende de un parámetro inicial que funciona como un disparador.

Normalmente la Mutación modifica un dígito de un gen cuando éste está en código binario. Sin embargo, ya que el proyecto representa los genes como número reales, se implementó la técnica de Mutación "No uniforme" (Michalewicz, 1996; Russell, 1996). El mecanismo de esta técnica se describe a continuación:

Cuando el parámetro de mutación se "dispara" en una generación durante la ejecución del AG, se selecciona un Individuo X: $X = (x_1, x_2, x_3, x_4, \ldots, x_n)$

Posteriormente, se determina una posición k aleatoriamente entre 1 y el número de total de genes del cromosoma. Esta posición determina qué gen va a ser el que será mutado dentro del individuo. Para que el individuo X, se convierta en:

$X' = (x_1, x_2, \ldots, x'_k, \ldots, x_{n-1}, x_n)$ Para:

$$x'_k = x_k + \Delta(t, UB - x_k), si\ R = Verdad$$
$$x'_k = x_k - \Delta(t, x_k - LB), si\ R = Falso$$

Donde:

R = número aleatorio entre 0 and 1
T = número máximo de generaciones
t = generación actual
b = grado de no uniformidad de mutación
LB = Límite inferior del gen x_k
UB = Límite superior del gen x_k

$$\Delta(t, y) = y * (1 - r^{(1-\frac{t}{T})^b})$$

6. Pruebas y Resultados

Para evaluar el conjunto de Algoritmos Genéticos propuestos en este trabajo, se diseñó un conjunto de pruebas divididas en dos etapas. La primera está denominada como "Prueba A" que consiste en ejecutar cinco pruebas individuales ("Test01", "Test02", "Test03", "Test04" y "Test05") por cada AG construido. Estas pruebas se ejecutaron para analizar el comportamiento de los AGs múltiples veces y analizar los resultados obtenidos. La característica principal de la "Prueba A" es que la generación de valores aleatorios para los genes de los cromosomas no están limitados deliberadamente, es decir que el AG tiene la libertad asignar un valor desde el límite inferior hasta el límite superior de cada gen. Esto se consideró necesario para explorar libremente el espacio de soluciones y poder identificar, por medio del análisis, variables específicas que posean un impacto relevante en el cálculo de PoF.

La segunda etapa de las pruebas es denominada como "Prueba B" que consiste en otras cinco pruebas más por cada AG, pero con la diferencia de que manualmente se ajustan los límites máximo y mínimo de una variable de interés. Esta variable es identificada por medio del

análisis de resultados de la "Prueba A", a través de la observación de variables que difieren sustancialmente entre el comportamiento de los individuos con resultados menos óptimos contra el comportamiento de los individuos con las soluciones más óptimas. En la Figura 1 se muestra un ejemplo del promedio de los genes de los individuos que producen los resultados más y menos óptimos para el "Test03" de la "Prueba A" para la amenaza de Operaciones Incorrectas. La línea inferior (azul) representa el comportamiento de los "mejores" individuos mientras que la línea superior (roja) representa el comportamiento de los "peores" individuos. Se puede apreciar en la Figura 1 que ambos cromosomas tienen valores aproximados, pero es notable que el valor del gen denominado como "Ajuste de Pérdida de Metal de la Pared del Ducto" varía considerablemente. De esta forma se puede asumir que es una variable de interés ya que su valor impacta de forma relevante al resultado final de la Probabilidad de Falla para esta amenaza en particular.

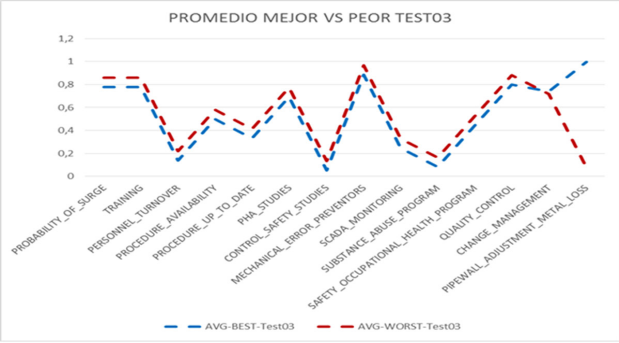

Figura 1. Comparativo del comportamiento de los valores promedio de los genes de Operaciones Incorrectas

Por lo tanto, para la "Prueba B" se seleccionó una variable de interés por cromosoma para analizar si con la limitación deliberada de esta variable, cada AG puede encontrar mejores soluciones comparadas con los resultados de la "Prueba B", ver resultados en sección 6.2.

6.1. Prueba A

Como se mencionó previamente, la "Prueba A" consiste en cinco ejecuciones por Algoritmo Genético, sin modificar los rangos de los genes, dándole la libertad al sistema a explorar en todo el espectro en los rangos de operación por variable. Las Figuras 2, 3, 4, 5, 6 y 7 muestran una comparación del promedio resultados de "Test01", "Test02", "Test03", "Test04", "Test05" por amenaza para los "mejores" y "peores" individuos, describiendo la "evolución" de los individuos desde el individuo uno hasta el cien. Es decir, que los valores optimizados fueron encontrados por el AG por medio de la exploración y selección.

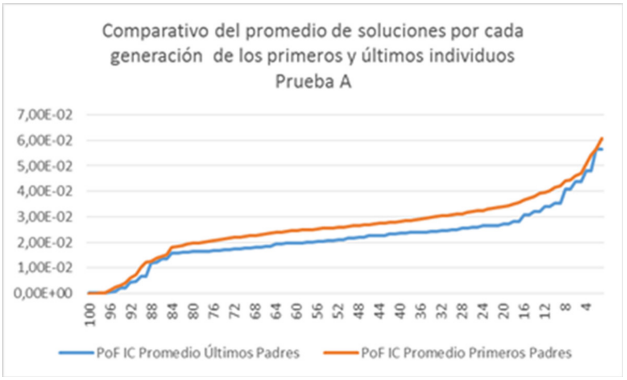

Figura 2. Comparativo del promedio de soluciones de Daño Mecánico Prueba A

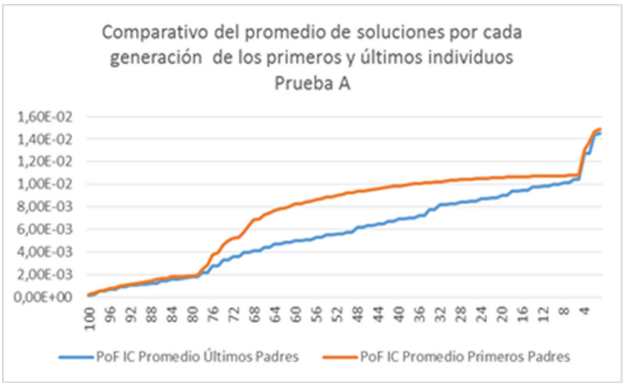

Figura 3. Comparativo del promedio de soluciones de Sabotaje y Robo Prueba A

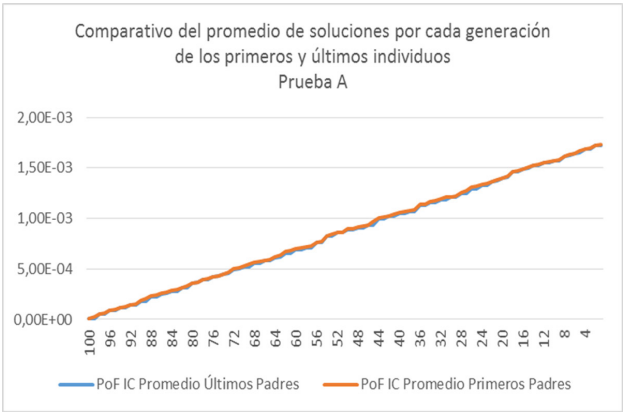

Figura 4. Comparativo del promedio de soluciones de Corrosión Interna Prueba A

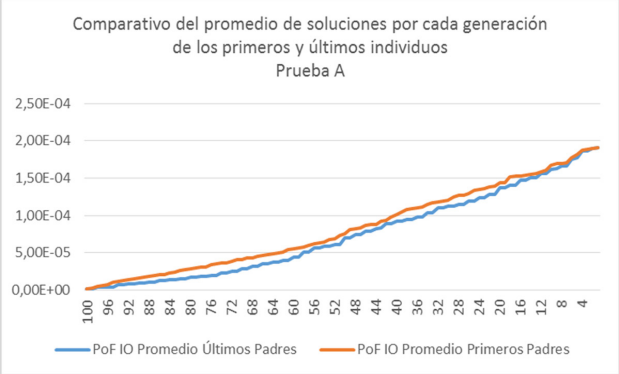

Figura 5. Comparativo del promedio de soluciones de Operaciones Incorrectas Prueba A

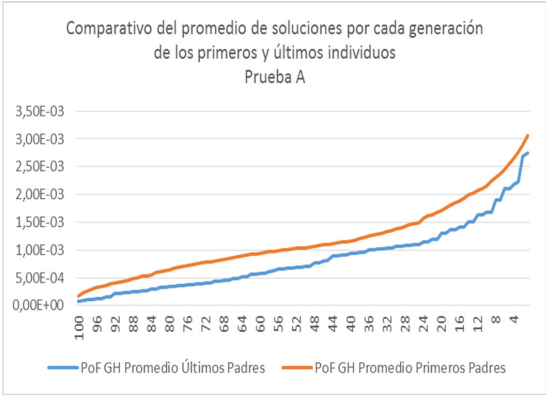

Figura 6. Comparativo del promedio de soluciones de Peligros Geográficos Prueba A

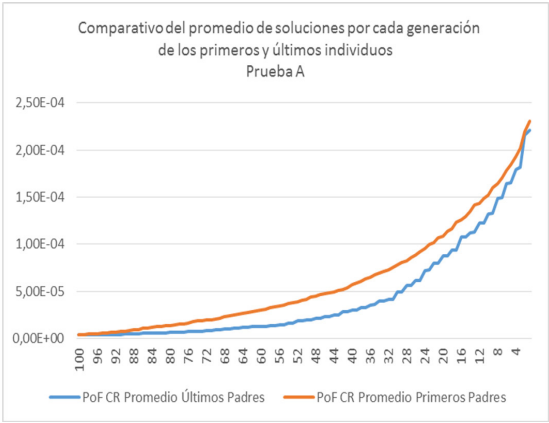

Figura 7. Comparativo del promedio de soluciones de Agrietamiento Prueba A

Incluso sin limitar los rangos de los genes, el Sistema propuesto pudo explorar diferentes combinaciones y seleccionar aquellas que mostraran mejor desempeño. Además de la notable minimización del valor de PoF, la diferencia entre la generación inicial y la última generación es evidente. Se puede notar que la generación número cien tiene mejores resultados en todos los casos, particularmente en la amenaza "Agrietamiento" (CR). Las Figuras 8, 9, 10, 11, 12, 13 y 14 muestran una comparación entre los valores de PoF para cada amenaza.

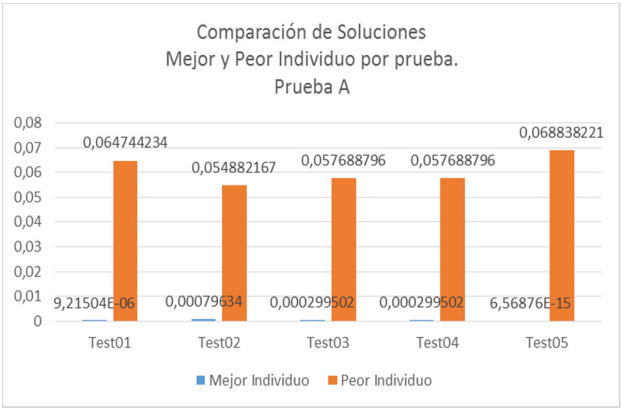

Figura 8. Comparativo de valores de soluciones, Daño Mecánico Prueba A.

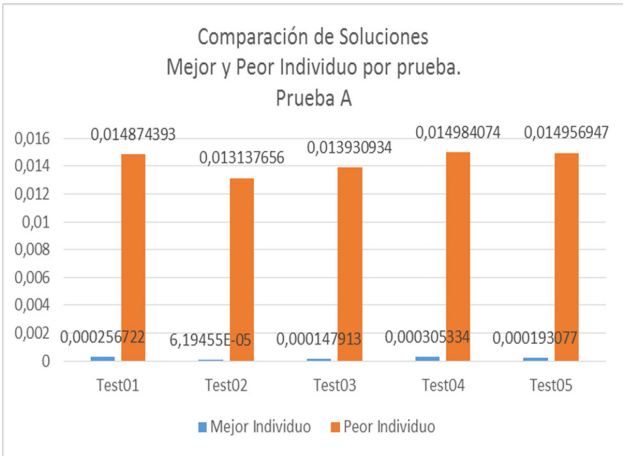

Figura 9. Comparativo de valores de soluciones, Sabotaje y Robo Prueba A.

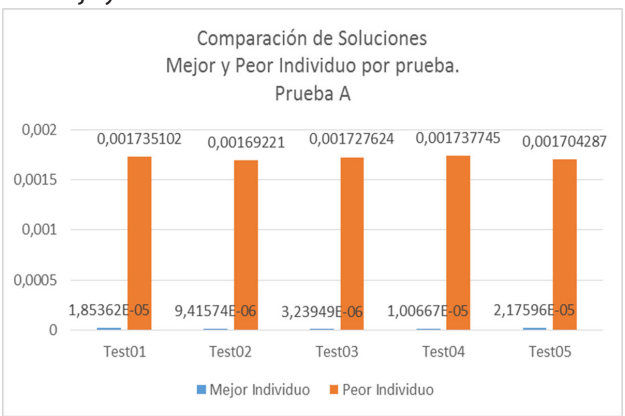

Figura 10. Comparativo de valores de soluciones, Corrosión Interna Prueba A.

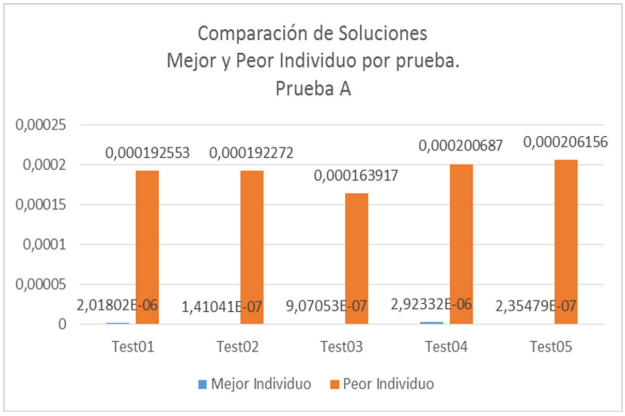

Figura 11. Comparativo de valores de soluciones, Operaciones Incorrectas Prueba A.

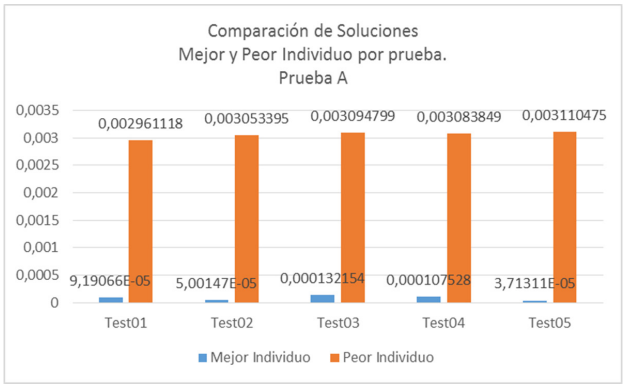

Figura 12. Comparativo de valores de soluciones, Peligros Geográficos Prueba A.

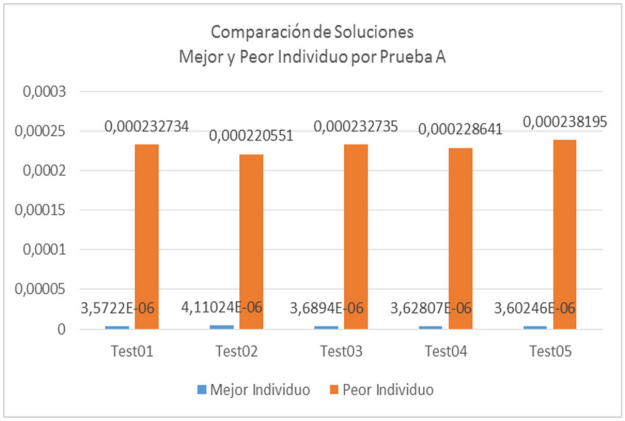

Figura 13. Comparativo de valores de soluciones, Agrietamiento Prueba A.

6.2. Prueba B

Una vez que se identificaron algunas variables de interés, una por amenaza, se limitaron los rangos de los genes con el objetivo de experimentar y ayudar a los AGs a optimizar los valores de PoF. La limitación de rangos consintió básicamente en reducir el rango de valores de un gen en cada cromosoma, acercando los valores ya sea al límite natural superior o inferior. De esta forma se encontró que estas simulaciones efectivamente generan resultados con mejor desempeño que los resultados obtenidos en la "Prueba A". Las Figuras 14, 15, 16, 17, 18 y 19, muestran la comparación entre los promedios de las sub pruebas "Test 01", "Test 02", "Test 03", "Test 04" y "Test 05", para mostrar la diferencia y el proceso "evolutivo" entre los "mejores" y los "peores" individuos de la "Prueba B".

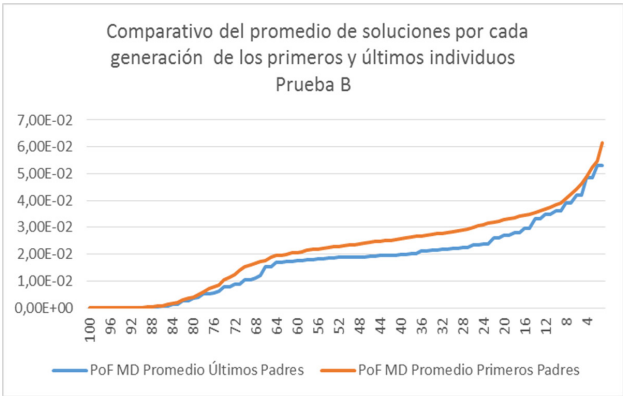

Figura 14. Comparativo del promedio de soluciones de Daño Mecánico Prueba B

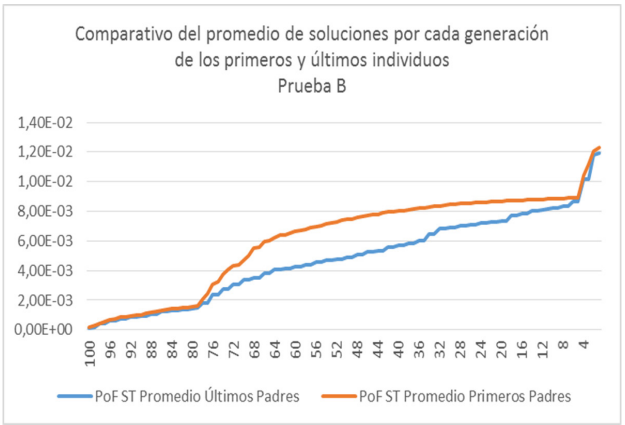

Figura 15. Comparativo del promedio de soluciones de Sabotaje y Robo Prueba B

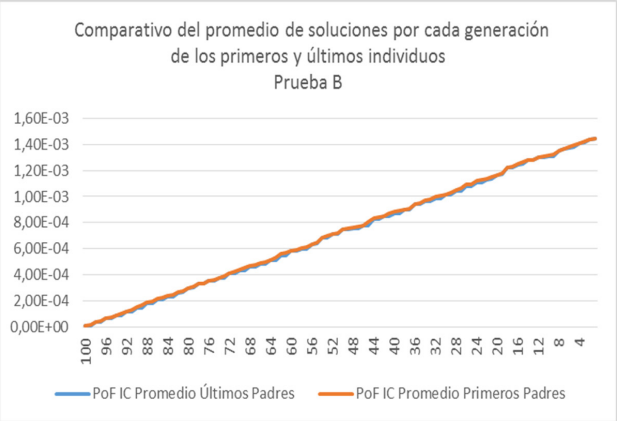

Figura 16. Comparativo del promedio de soluciones de Corrosión Interna Prueba B

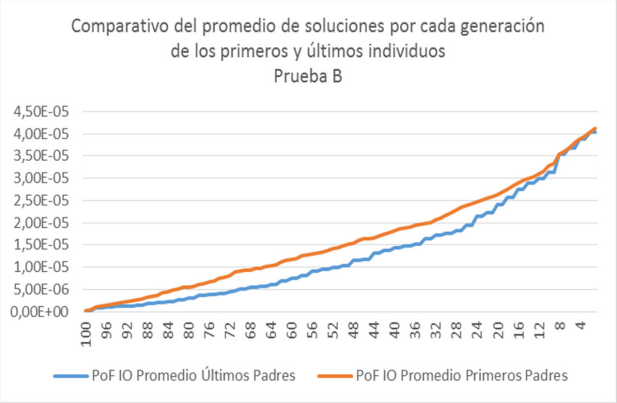

Figura 17. Comparativo del promedio de soluciones de Operaciones Incorrectas Prueba B

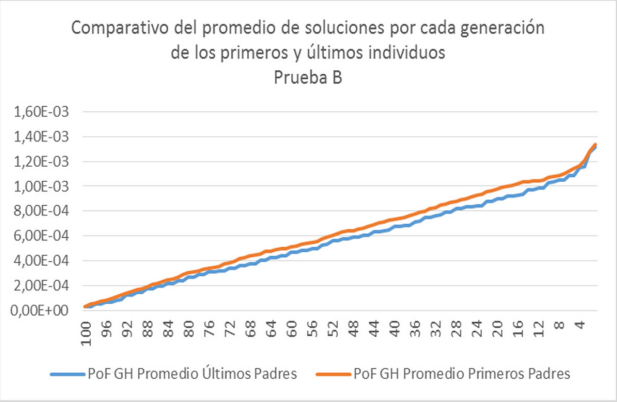

Figura 18. Comparativo del promedio de soluciones de Peligros Geográficos Prueba B

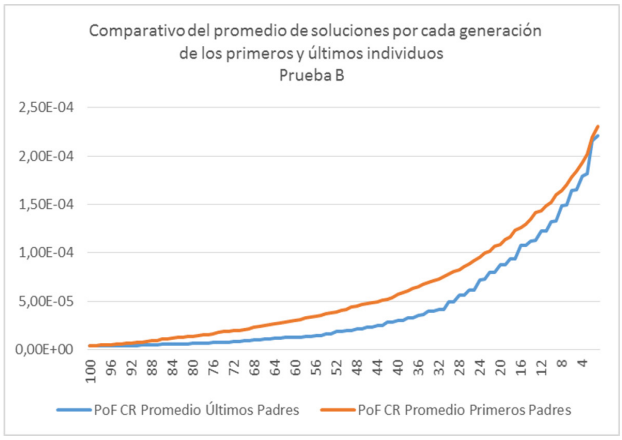

Figura 19. Comparativo del promedio de soluciones de Agrietamiento Prueba B

Las Figuras 20, 21, 22, 23, 24 y 25 muestran la comparación entre valores de PoF generados por los "mejores" y "peores" individuos para describir la variación entre los resultados de la primera generación y las soluciones óptimas encontradas por el sistema.

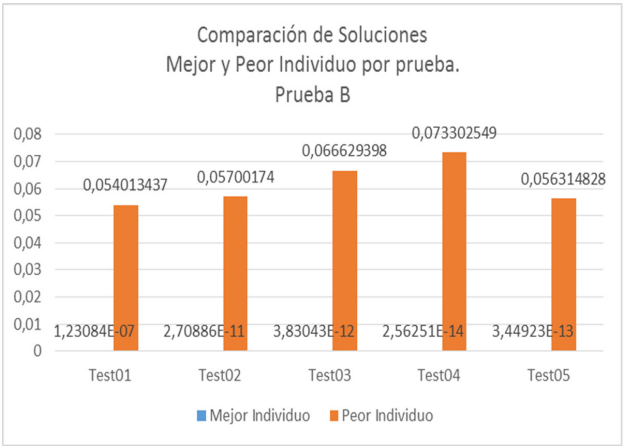

Figura 20. Comparativo de valores de soluciones, Daño Mecánico Prueba B.

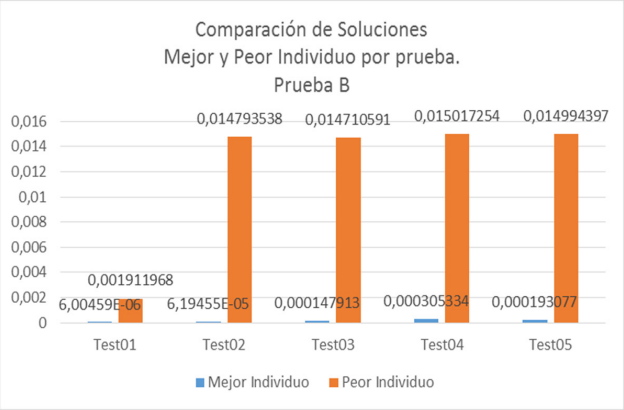

Figura 21. Comparativo de valores de soluciones, Sabotaje y Robo Prueba B.

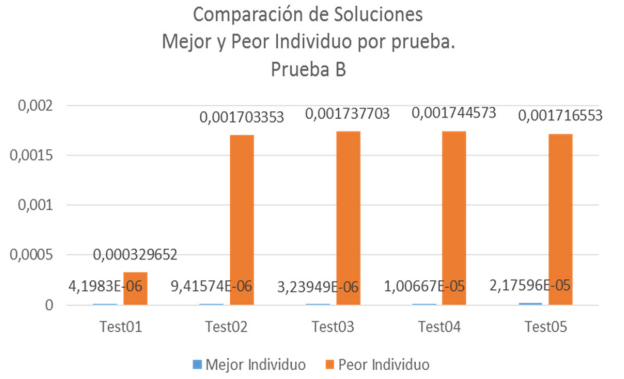

Figura 22. Comparativo de valores de soluciones, Corrosión Interna Prueba B.

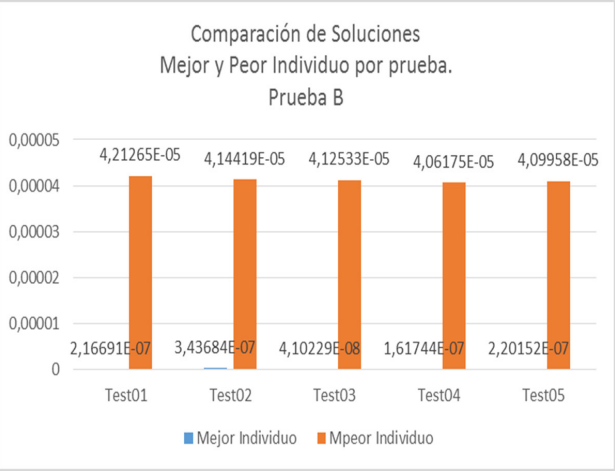

Figura 23. Comparativo de valores de soluciones, Operaciones Incorrectas Prueba B.

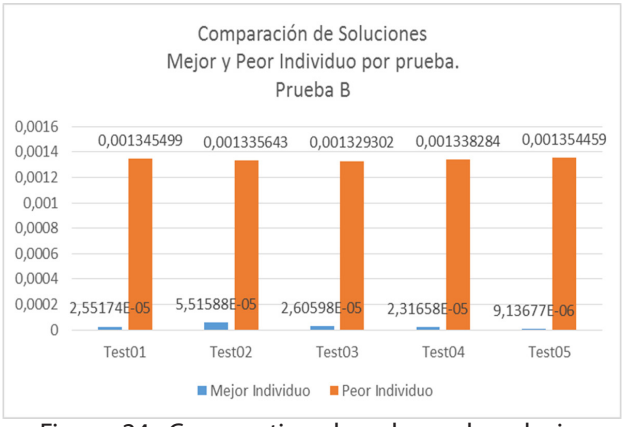

Figura 24. Comparativo de valores de soluciones, Peligros Geográficos Prueba B.

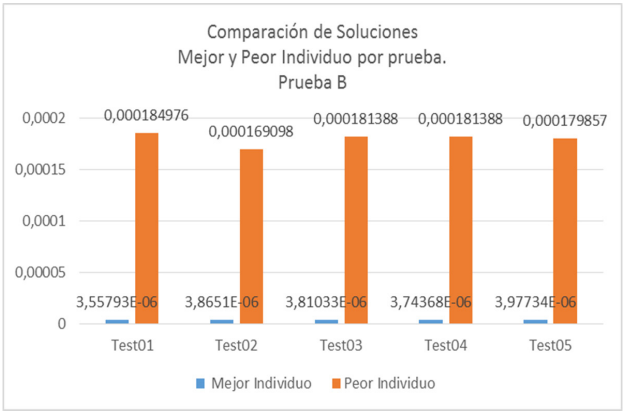

Figura 25. Comparativo de valores de soluciones, Agrietamiento Prueba B.

Los resultados generados en ambas etapas, la "Prueba A" y la "Prueba B" muestran variaciones significativas en los resultados entre generaciones. Esto quiere decir que al operar, los AGs encontraron formas de optimizar las soluciones por medio de la exploración del espacio de los valores de los genes. Además, los resultados de la "Prueba B" mostraron que los cromosomas utilizados aquí desarrollaron un mejor desempeño que los cromosomas de la "Prueba A". Las Figuras 26, 27 y 28 muestran una comparación entre los promedios de todos los resultados de las soluciones finales, es decir de la última generación, contra la soluciones generadas por los primeros padres.

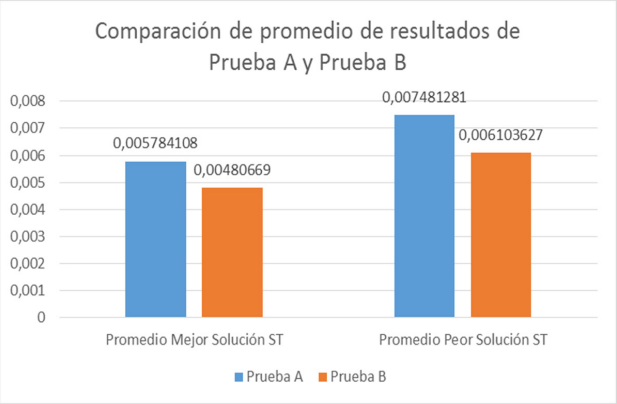

Figura 26. Comparativo de valores promedio de Sabotaje y Robo de la Prueba A contra Prueba B

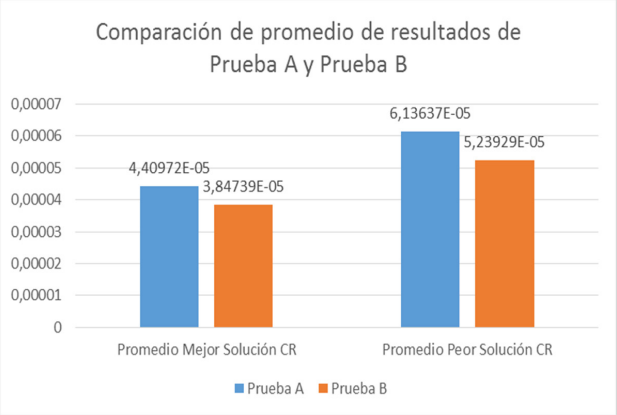

Figura 27. Comparativo de valores promedio de Agrietamiento de la Prueba A contra Prueba B

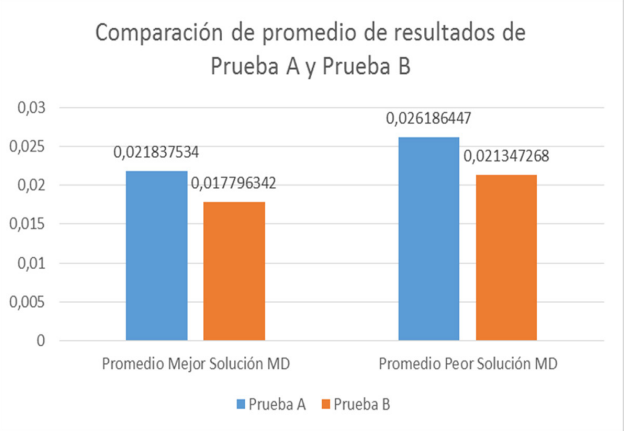

Figura 28. Comparativo de valores promedio de Daño Mecánico de la Prueba A contra Prueba B.

Estas Figuras muestran que los individuos evolucionan, generando soluciones más óptimas en la última generación que en la primera. En la Tabla 5 se toman tres ejemplos en donde se compara el promedio de mejores y peores resultados de la Prueba A y Prueba B para las amenazas de Agrietamiento, Daño Mecánico y Sabotaje. En la Tabla 5 se puede observar que el AG optimizó la solución para Agrietamiento (CR) reduciendo la PoF al 1.6% del valor generado por el peor individuo de la primera generación para la Prueba A, mientras que para la Prueba B se optimizó al 2.11%. Para el caso de Daño Mecánico (MD), se encontró una optimización al 0.4% para la Prueba A y 0.000040069% para la Prueba B. Para el caso de Sabotaje y Robo (ST) el Sistema encontró una optimización al 1.34% para la Prueba A y un 1.162% para la Prueba B.

Tabla 4. Comparación de promedios de mejores y peores individuos de la Prueba A y Prueba B

	CR Prueba A	CR Prueba B	MD Prueba A	MD Prueba B	ST Prueba A	ST Prueba B
Mejor Individuo	3,7205E-06	3,7909E-06	0,00028091	2,4623E-08	0,000193	0,00014285
Peor Individuo	0,00023057	0,00017934	0,06076844	0,06145239	0,0143768	0,01228555

La comparación entre los resultados de la Prueba A contra la Prueba B señalan que al identificar y manualmente limitar los rangos de una variable de interés, se puede generar una optimización generalizada en cada caso. Consideramos esta diferencia representa un dato importante, ya que se pudieron construir simulaciones que minimizaron la Probabilidad de Falla de un ducto, esto quiere decir que el Sistema puede ser una herramienta que permita a los usuarios expertos identificar características del segmento de ducto para reducir el riesgo o encontrar una forma detener una amenaza o mitigar sus efectos.

7. CONCLUSIONES

El petróleo y todos los procesos a su alrededor son un pieza fundamental en la economía a nivel mundial gracias al alto impacto que esta industria tiene sobre nuestras vidas y la sociedad en general. No sólo dependemos del petróleo como fuente de combustible sino de sus otros dos mil productos derivados del crudo que son relevantes en nuestra vida cotidiana.

Existen muchas maneras para transportar el petróleo desde los yacimientos o pozos de extracción. Sin embargo, el medio más utilizado es el sistema a de tuberías o ductos que recorren grandes distancias para distribuirlo en diferentes puntos del país, e incluso fuera

de él. Y a pesar de su alto grado de confianza, es indispensable que se lleve un control sobre la operación y el estado actual del ducto. Para ello, la industria en conjunto con el gobierno y universidades, colaboran para desarrollar tecnología de punta y metodologías para optimizar los procesos de transformación, refinación, extracción y administración de los procesos de petróleo. La industria petrolera en México como en la mayoría de los países necesita constantemente ajustar sus metodologías a las regulaciones nacionales e internacionales para mejorar sus protocolos de control.

Por medio de los Algoritmos Genéticos, este proyecto desarrolló un conjunto de sistemas a bajo costo para encontrar posibles configuraciones que generen soluciones optimizadas para reducir o minimizar el valor de Probabilidad de Falla (PoF) durante el proceso de Evaluación de Integridad de Ductos para asistir a la Administración de Riesgo y la Logística para el Trasporte de Hidrocarburos.

Por medio del conjunto de sistemas desarrollados en este trabajo se logró encontrar un valor optimizado en las seis amenazas estudiadas. Por ejemplo, se logró encontrar un valor minimizado al 1.64% del valor inicial de 0.00023 al 0.0000037 del Agrietamiento. Para el caso del Daño Mecánico un valor optimizado del 0.00004.05% para el valor inicial de 0.0607 al 0.0000002462. Para la amenaza de Sabotaje y Robo se encontró un valor optimizado al 0.99% del valor inicial de 0.014 a 0.000142. Estos valores muestran que el conjunto de Algoritmos Genéticos construidos en este trabajo, representan una herramienta con gran potencial para asistir al proceso de toma de decisiones.

En las industrias alrededor del mundo, el proceso de toma de decisiones es de suma importancia porque no sólo es para interés y crecimiento propio de las empresas u organizaciones, sino en muchos casos, estas decisiones afecta de forma directa a la sociedad. El Riesgo que en la mayoría de las industrias es un tema al que se le da mucha importancia y unos de los esfuerzos es diseñar metodologías de cómo medirlo y minimizarlo. Para la industria petrolera, la medición, evaluación y administración del riesgo es extremadamente importante, de ahí la necesidad de colaborar con otras instituciones para desarrollar herramientas que permitan adquirir conocimiento exacto, preciso y oportuno.

Por esta razón creemos que, como Sistema de Soporte de Decisiones (DSS), este proyecto representa una oportunidad valiosa, de bajo costo económico y operacional, para asistir al personal responsable del proceso de toma de decisiones, proveyendo asistencia para identificar configuraciones óptimas para reducir o minimizar la Probabilidad de Falla de un segmento de ducto e incluso a poder determinar de forma inteligente la asignación de recursos por medio de escenarios y finalmente, colaborar en la reducción de accidentes o siniestros asociados a la falla de ductos para el trasporte de hidrocarburos.

REFERENCIAS

1. ASME B31.8S (2010). Suplemento a la norma B31.8 en Managing System Integrity of Gas Pipelines, American Society of Mechanical Engineers, ASME.

2. ASME B31.4 (2002). Pipeline Transportation Systems for Liquid Hydrocarbons and other Liquids, American Society of Mechanical Engineers, ASME.

3. Canto, J. & Zargo, R. (2016). Diagnóstico de la logística del Petróleo y sus Derivados en Argentina, Universidad Nacional de La Plata, Facultad de Ingeniería, Argentina. Consultado en Junio 2017: https://labs.ing.unlp.edu.ar/uidic/archivos_publicaciones/tmp/Diagn%C3%B3stico%20de%20la%20Log%C3%ADstica%20del%20petroleo%20y%20sus%20derivados%20en%20Argentina.pdf

4. Chow, S. (1987). Petroquímica y Sociedad, La Ciencia desde México, Fondo de Cultura Económica, ISBN 968-16-2669-9, México.

5. Coello, C. A. (2014). Introducción a la Computación Evolutiva, Ciudad de México, México: IPN, CINVESTAV, Departamento de Ciencias Computacionales.

6. Érij V., Rásina, M. & Rudin, M. (1988). Química y tecnología del petróleo y del gas, Editorial Mir Moscú, ISBN 5-03-000698-2.

7. Cosham, A. & Hopkings, P. (2003). The assessment of Corrosion in Pipelines – Guidence in the Pipeline Defect Assessment Manual (PDAM), Presentado en el International Colloquium 'Reliability of High Pressure Steel Pipelines', Praga, República Checa.

8. Goodfellow, G. & Haswell, J. (2006). A comparison of Inherent Risk Levels in ASME B31.8 and UK Gas Pipeline Design Codes, ICP2006-10507, Presentado en el ICP2006, 6° Conferencia Internacional sobre Ductos, Canadá.

9. Hopkins, P., Goodfellow, G., Ellis, R., Haswell, J. & Jackson, N. (2009), Pipeline Risk Assessment: New Guidelines, Australia, WTIA/APIA Welded Pipeline Symposium.

10. Hopkins, P (2000). Pipeline Integrity Reviews, Presentado en la Conferencia Internacional sobre Ductos, México.

11. Jen C., T, Chin Yang, S., Jung Chang, K. (2009). Portfolio optimization problems in different risk measures using genetic algorithm, Departamento de Negocios Internacinales de la Universidad Shih Chien, Departamento de Ciencias Computacionales del Instituto de Tecnología de Chung Cheng, Universidad de la Defensa Nacional, Taiwan, Elsevier, Expert Systems with Applications, Volumen 36, Número 7.

12. Kasemsap K. (2016). The Fundamentals of Business Intelligence, International Journal of Organizational and Collective Intelligence, Volumen 6, Issue 2.

13. Michalewicz, Z. (1996). Genetic Algorithms + Data Structures = Evolution Programs, Springer-Verlag, Tercer Edición, Estados Unidos.

14. Muhlbauer, W. K. (2006). Enhanced Pipeline Risk Assessment. Parte 1, Evaluaciones de Probabilidad de Falla, Revisión 2.1, Consultado el 2006 en www.pipelinerisk.com/downloads.

15. NOM027-SESH-2010 (2010). Administración de la integridad de ductos de recolección y transporte de hidrocarburos, México, Norma Oficial Mexicana, Secretaría de Energía.

16. PEMEX, Petróleos Mexicanos (2008). Seguridad, Salud y Protección Ambiental, Análisis de Riesgos y Programas de Seguridad en Instalaciones de PEMEX, PEMEX

17. Ramírez, R., Godoy A., Martínez J. L., Muhlbauer, W. K. & Alva, A. (2014). Development of a probabilistic pipeline risk assessment software for Mexico's oil state company. Presentado en la Conferencia Internacional sobre Ductos, Volumen 3: Materials and Joining; Risk Reliability, ISBN: 978-07918-4612-4, ASME.

18. Ramírez, R., Godoy, A., Martínez, J. L., Muhlbauer, W. K. & Alva, A. (2013). Desarrollo de un modelo probabilístico de nueva generación para el análisis de riesgos en ductos. Presentado en el 2° Congreso y Exposición Internacional de Logística, Transporte y Distribución de Hidrocarburos, México.

19. Rich, E. & Knight, K. (1994). Inteligencia Artificial. McGrawHill, España ISBN0-07-052263-4.

20. Russell, S. & Norving, P. (1996). Artificial Intelligence a modern approach, Estados Unidos, Prentice Hall Inc, ISBN 0-13-103805-2.

21. Sabherwal, R. and Becerra, I. (2011). Business Intelligence Practices, Technologies, and Management, Estados Unidos, John Wiley & Sons.

22. Sosa, M. C. (2007). Inteligencia artificial en la gestión financiera empresarial, Universidad del Atlántico, Colombia.

23. PEMEX, Petróleos Mexicanos (2011). Informe de Responsabilidad Social, PEMEX.

24. Pfeifer J., Barker K., Ramirez J. E., and Morshedlou N. (2015). Quantifying the risk of project delays with a genetic algorithm, School of industrial and Systems Engineering. Universidad de Oklahoma, School of Systems and Enterprises, Stevens Institute of Technology y Tec de Monterrey, Colegio de Cienca y Tecnología en Zapopan. Estados Unidos y México, Elsevier, International Journal of Production Economics, Volume 170, Parte A.

SEMBLANZA

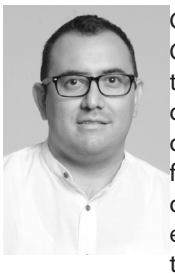

Gustavo Calzada Orihuela, nacido en Cuernavaca, Morelos, obtuvo su grado y título en Ingeniería en Computación y Redes de Computadoras por la Universidad Morelos de Cuernavaca en el 2011. Continuó su formación académica en el Centro Nacional de Investigación y Desarrollo Tecnológico en el Departamento de Ingeniería de Software, trabajando en arquitecturas de Inteligencia de Negocios, Cubos de Datos y Almacenes de Datos. En el 2013 obtuvo el grado de Maestro en Ciencias en Ciencias Computacionales, además de colaborar como Estudiante Asociado y posteriormente como Asistente de Investigador en el ICF de la UNAM. En 2014, recibió una beca del PNPC para sus estudios en el Doctorado en Ingeniería y Ciencias Aplicadas en el CIICAP en la Universidad Autónoma del Estado de Morelos, donde continúa su trabajo en la investigación y desarrollo de análisis y aplicaciones de Inteligencia Artificial, Inteligencia de Negocios y Big Data para la industria del petróleo.

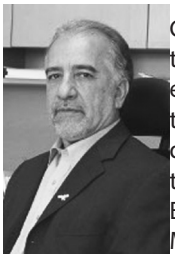

Gustavo Urquiza Beltrán recibió, en 1978, su título de Ingeniero en Ingeniería Mecánica en el Instituto Tecnológico de Culiacán, trabajando con el Uso de Cambiadores de Calor de Contacto Directo. Recibió su título de Maestro en Ingeniería Mecánica y Eléctrica en la Escuela Superior de Ingeniería Mecánica y Eléctrica en el IPN, donde trabajó en el Estudio del Efecto Dinámico de las Estelas en un Intercambiador de Calor Tubular Sumergido. Realizó sus estudios de doctorado en el Departamento de Ingeniería Mecánica de la Escuela Politécnica de Montreal, Canadá, trabajando en el Estudio del Flujo y Transferencia de Calor en Cavidades Cilíndricas en Rotación encontradas en máquinas para la generación de Energía. En 2003 se convirtió en profesor investigador en el CIICAP y posteriormente fue nombrado Director hasta el año 2012. Fue Secretario de Investigación en la UAEM hasta el 2015 cuando fue nombrado Secretario Académico de la misma Universidad.

Jorge A. Ascencio Gutiérrez, originario de Zapotlán el Grande, Jalisco, recibió su título de Licenciatura en Física en la Facultad de Ciencias en la Universidad de Guadalajara. Recibió una beca del CONACyT para realizar sus estudios de maestría en Ciencias en la UNAM. En el año 1998 fue nombrado Jefe del Departamento de Física Computacional Así mismo, recibió su título de Doctor en la Universidad Autónoma del Estado de México en el año 2000. Estudió su Postdoctorado en el Instituto Mexicano del Petróleo en 2002. En 2007 se unió al ICF de la UNAM como investigador y miembro del grupo de Materiales. En la actualidad colabora activamente con la Universidad Politécnica de Quintana Roo, trabajando en el desarrollo de biopaneles genéticos para evaluar la actividad física de los seres humanos.

Gerardo Reyes Salgado, recibió en 1982 su título en Ingeniería Civil en el Instituto Tecnológico de Zacatepec. Posteriormente continuó sus estudios recibiendo su grado de Maestro en Ciencias en Ciencias de la Computación en el Centro Nacional de Investigación y Desarrollo Tecnológico (CENIDET) en 1995, donde trabajó con Sistemas Expertos para la Adquisición Automática de Conocimiento. En 1997 recibió su diploma en Estudios Avanzados del Instituto Nacional Politécnico de Grenoble donde trabajó en el Conocimiento de Redes Neuronales Artificiales. Actualmente es profesor investigador en el Departamento de Ciencias Computacionales en el CENIDET donde se unió al grupo de Investigación en Inteligencia Artificial, trabajando con Machine learning, Optimización con sistemas evolutivos, Inteligencia Artificial y Sistemas Cognitivos. Posteriormente recibió su grado de Doctor en Ciencias Cognitivas en el Instituto Nacional Politécnico de Grenoble, trabajando con Conocimiento de Alto Nivel en Sistemas Híbridos Neuro Simbólicos.