

**SIMULACIÓN DE LA PROTECCIÓN CATÓDICA DE UNA TUBERÍA
ENTERRADA DE ACERO AISI 1020 UTILIZANDO ELEMENTOS DE
CONTORNO, ALGORITMOS GENÉTICOS Y TEORÍA FUZZY**

Luis Fernando Lemus Torres

**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICOQUÍMICAS
ESCUELA DE INGENIERÍA METALÚRGICA Y CIENCIA DE MATERIALES
PROGRAMA DE MAESTRÍA EN INGENIERÍA METALÚRGICA
2005**

**SIMULACIÓN DE LA PROTECCIÓN CATÓDICA DE UNA TUBERÍA
ENTERRADA DE ACERO AISI 1020 UTILIZANDO ELEMENTOS DE
CONTORNO, ALGORITMOS GENÉTICOS Y TEORÍA FUZZY**

Luis Fernando Lemus Torres

**Trabajo de investigación para optar al Título de Magíster en Ingeniería
Metalúrgica**

**Director
CUSTORIO VÁSQUEZ QUINTERO
MSc. Ingeniero Metalúrgico**

**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICOQUÍMICAS
ESCUELA DE INGENIERÍA METALÚRGICA Y CIENCIA DE MATERIALES
PROGRAMA DE MAESTRÍA EN INGENIERÍA METALÚRGICA
2005**

A Daniel Eduardo Lemus hijo y amigo fuente de todo mi valor y empeño
A mi Padre, se que estarías orgulloso
A mi Madre y hermanos

AGRADECIMIENTOS

El autor expresa sus sinceros agradecimientos a

El Profesor Custodio Vázquez Quintero por todo el apoyo brindado durante el desarrollo de esta investigación, sus indicaciones enriquecieron el aporte científico del trabajo y brindaron luces antes no vistas.

Al postgrado de Ingeniería Metalúrgica y todo su cuerpo de docentes que durante mi permanencia en la maestría me ofrecieron su apoyo irrestricto, requisito imprescindible para culminar con éxito el reto propuesto.

Al grupo de Corrosión, espacio precioso de aprendizaje e investigación, célula inspiradora de innovación, desarrollo y excelencia.

TÍTULO SIMULACIÓN DE LA PROTECCIÓN CATÓDICA DE UNA TUBERÍA ENTERRADA DE ACERO AISI 1020 UTILIZANDO ELEMENTOS DE CONTORNO, ALGORITMOS GENÉTICOS Y TEORÍA FUZZY¹

Autor: Luis Fernando Lemus Torres²

Palabras claves: Protección catódica, corrosión en suelos, simulación numérica, curva de polarización, elementos de contorno, algoritmos genéticos, agrupamiento borroso, sistemas basados en reglas borrosas.

La protección catódica es el sistema de protección contra la corrosión más utilizado por la industria del transporte de fluidos, consiste en hacer que la estructura a proteger sea el cátodo de la celda electrolítica. Para simular sistemas de este tipo es necesario solucionar la ecuación de Laplace para el potencial utilizando como condiciones de frontera: la densidad de corriente cero en las superficies aisladas y la interface aire – suelo, densidad de corriente preestablecida en los electrodo de corriente impresa, y la curva de polarización, que es una relación matemática entre las dos principales variables: densidad de corriente y potencial, sobre la superficie del metal. Esta última debe ser obtenía experimentalmente y no siempre se encuentra disponible.

En el presente trabajo se estudió el problema de la corrosión en suelos de tuberías enterradas, se agruparon los suelos según su corrosividad utilizando agrupamiento borroso, se desarrolló una metodología para predecir la curva de polarización de un acero AISI 1020 enterrado en suelos arcillosos a partir de los parámetros fisicoquímicos del suelo por medio de la generación automática de un sistema basado en reglas borrosas, se simuló numéricamente un sistema de protección catódica utilizando el método de los elementos de contorno, se optimizó la posición y corriente de los electrodos de corriente impresa de un sistema de protección catódica utilizando algoritmos genéticos.

Por primera vez se obtuvo el estado de polarización de un metal enterrado en un suelo sin realizar pruebas potencioestáticas, utilizando para ello la resistividad, el pH, las concentraciones de iones cloruro, carbonato y el porcentaje de agua en el suelo. La metodología produjo una correlación de entre 0.92 y 0.999 con respecto a los datos experimentales de entrenamiento, adicionalmente fue validada con datos experimentales.

¹ Trabajo de Investigación

² Facultad de Ingenierías Fisicoquímicas. Postgrado en Ingeniería Metalúrgica.
Director: Custodio Vásquez Quintero, Escuela de Ingeniería Metalúrgica y ciencia de Materiales, Universidad Industrial de Santander, Bucaramanga, Colombia.

TITLE: CATHODIC PROTECTION SIMULATION OF A AISI 1020 STEEL BURIED PIPE USING BONDARY ELEMENTS, GENETIC ALGORITHMS AND FUZZY THEORY.

Author: Luis Fernando Lemus Torres³

Keywords. Cathodic protection, underground corrosion, numeric simulation, polarization curve, boundary elements, genetic algorithms, fuzzy clustering, fuzzy base rule systems.

Cathodic protection is the most used protection system against corrosion by the fluid transport industry, it consists to make the structure to be protect becomes the cathode in the electrolytic cell. In order to simulate this kind of problems is necessary to solve the Laplace equation for potential using like boundary conditions: zero current density on the isolate surfaces and the air-soil interface, a know current density on the impressed current electrodes, and the polarization curve, which is a mathematical relationship between the two main variables: current density and potential, on metal structure surface. This last condition has to be obtained experimentally and no even is available.

In this work the buried pipes underground corrosion problem was studied, a fuzzy clustering of soils by their corrosiveness were performed. A methodology to predict the polarization curve of buried AISI 1020 steel from the soil's physic-chemical parameters using a automatic generation of fuzzy rule base system was developed. A cathodic protection numeric simulation using boundary element method was performed, and the electrodes' positions and current density were optimized using genetic algorithms.

The polarization state of a buried metal was obtained, for the first time, without to take potentiostatics tests, using the soil resistivity, pH, humidity percentage, and Cl^- CaCO_3 concentrations for this task. The methodology produced a correlation between 0.92 and 0.999 with the experimental training data; in addition it was validated with other experimental ones.

³ Facultad de Ingenierías Fisicoquímicas. Postgrado en Ingeniería Metalúrgica.
Director: Custodio Vásquez Quintero, Escuela de Ingeniería Metalúrgica y ciencia de Materiales, Universidad Industrial de Santander, Bucaramanga, Colombia.

TABLA DE CONTENIDO

INTRODUCCION	1
1. MARCO TEORICO	7
1.1. Modelo Numérico de la Protección Catódica	7
1.1.1 Condiciones de Frontera	9
1.2. Método de los elementos de Contorno en la Protección Catódica	10
1.3 Optimización de Protección Catódica	12
1.3.1 Algoritmos Genéticos	13
1.4. Predicción de la Curva de Polarización	15
1.4.1 Agrupamiento Difuso	16
1.4.2 Predicción de la curva de polarización por lógica borrosa	21
1.4.2.1 Lógica borrosa	22
1.4.2.2 Sistemas Basados en Reglas Difusas	24
1.4.3 Generación Automática de Reglas Base de Lógica Difusas	25
2. METODOLOGÍA DE SOLUCIÓN NUMERICA DEL PROBLEMA	31
2.1 Predicción de la curva de polarización de un metal enterrado	33
2.1.1 Agrupamiento de los suelos	33
2.1.2 Generación de Reglas Base de Lógica Difusa	35
2.2 Optimización de la Protección Catódica	37
2.2.1 Método Efectivo de Elementos de Contorno	37
2.2.1.1 Solución Numérica por Elementos Constantes	38
2.2.2 Optimización de Protección Catódica por Algoritmos Genéticos	41
3. ANALISIS DE RESULTADOS	43
3.1 Predicción de la curva de polarización del acero AISI 1020 enterrado en un suelo arcilloso	43
3.1.1 Agrupamiento de los suelos	43
3.1.1.1 Selección del corte	45
3.1.2 Obtención del sistema basado en reglas borrosas	47
3.1.2.1 Grupo de suelos de baja corrosividad	48
3.1.2.1.1 Generación del sistema para U1	48
3.1.2.1.2 Generación del sistema para U2	51
3.1.2.1.3 Generación del sistema para U3	52
3.1.2.1.4 Predicción de B1	56
3.1.2.1.5 Predicción de B2	57
3.1.2.1.6 Predicción de B3	59
3.1.2.1.7 Predicción de IL	60
3.1.2.2 Grupo de suelos de corrosividad media	63
3.1.2.2.1 Generación del sistema para U1	63
3.1.2.2.2 Generación del sistema para U2	65
3.1.2.2.3 Generación del sistema para U3	68
3.1.2.2.4 Predicción de B1	69
3.1.2.2.5 Predicción de B2	72

3.1.2.2.6 Predicción de B3	73
3.1.2.2.7 Predicción de IL	74
3.1.2.3 Grupo de suelos de corrosividad alta	76
3.1.2.3.1 Generación del sistema para U1	77
3.1.2.3.2 Generación del sistema para U2	80
3.1.2.3.3 Generación del sistema para U3	82
3.1.2.3.4 Predicción de B1	85
3.1.2.3.5 Predicción de B2	87
3.1.2.3.6 Predicción de B3	88
3.1.2.3.7 Predicción de IL	90
3.2 Optimización de la protección catódica	92
4. CONCLUSIONES	96
5. RECOMENDACIONES	97
6. REFERENCIAS BIBLIOGRÁFICAS	98

LISTA DE FIGURAS

Figura 1.1 Condiciones de Frontera de la protección Catódica	10
Figura 3.1 Número de suelos de corrosividad media agrupados Vs corte .	46
Figura 3.2 Número de suelos de corrosividad baja agrupados Vs corte .	46
Figura 3.3 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de U1 en suelos de baja corrosividad.	50
Figura 3.4 Ajuste del algoritmo a los valores de salida de U1 durante la fase de entrenamiento del sistema basado en reglas para suelos de baja corrosividad	51
Figura 3.5 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de U2 en suelos de baja corrosividad	53
Figura 3.6 Ajuste del algoritmo a los valores de salida de U2 durante la fase de entrenamiento del sistema basado en reglas para suelos de baja corrosividad	53
Figura 3.7 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de U3 en suelos de baja corrosividad.	55
Figura 3.8 Ajuste del algoritmo a los valores de salida de U3 durante la fase de entrenamiento del sistema basado en reglas para suelos de baja corrosividad	55
Figura 3.9 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de B1 en suelos de baja corrosividad.	57
Figura 3.10 Ajuste del algoritmo a los valores de salida de B1 durante la fase de entrenamiento del sistema basado en reglas para suelos de baja corrosividad	58
Figura 3.11 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de B2 en suelos de baja corrosividad.	59
Figura 3.12 Ajuste del algoritmo a los valores de salida de B2 durante la fase de entrenamiento del sistema basado en reglas para suelos de baja corrosividad	59
Figura 3.13 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de B3 en suelos de baja corrosividad.	61
Figura 3.14 Ajuste del algoritmo a los valores de salida de B3 durante la fase de entrenamiento del sistema basado en reglas para suelos de baja corrosividad	62
Figura 3.15 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de IL en suelos de baja corrosividad.	62
Figura 3.16 Ajuste del algoritmo a los valores de salida de IL durante la fase de entrenamiento del sistema basado en reglas para suelos de baja corrosividad	63
Figura 3.17 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de U1 en suelos de corrosividad media.	65
Figura 3.18 Ajuste del algoritmo a los valores de salida de U1 durante la fase de entrenamiento del sistema basado en reglas para suelos de corrosividad media	66

Figura 3.19 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de U2 en suelos de corrosividad media	67
Figura 3.20 Ajuste del algoritmo a los valores de salida de U2 durante la fase de entrenamiento del sistema basado en reglas para suelos de corrosividad media	68
Figura 3.21 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de U3 en suelos de corrosividad media.	70
Figura 3.22 Ajuste del algoritmo a los valores de salida de U3 durante la fase de entrenamiento del sistema basado en reglas para suelos de corrosividad media.	70
Figura 3.23 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de B1 en suelos de corrosividad media.	71
Figura 3.24 Ajuste del algoritmo a los valores de salida de B1 durante la fase de entrenamiento del sistema basado en reglas para suelos de corrosividad media	72
Figura 3.25 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de B2 en suelos de corrosividad media.	73
Figura 3.26 Ajuste del algoritmo a los valores de salida de B2 durante la fase de entrenamiento del sistema basado en reglas para suelos de corrosividad media	74
Figura 3.27 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de B3 en suelos de corrosividad media.	75
Figura 3.28 Ajuste del algoritmo a los valores de salida de B3 durante la fase de entrenamiento del sistema basado en reglas para suelos de corrosividad media	75
Figura 3.29 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de IL en suelos de corrosividad media	76
Figura 3.30 Ajuste del algoritmo a los valores de salida de IL durante la fase de entrenamiento del sistema basado en reglas para suelos de corrosividad media	77
Figura 3.31 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de U1 en suelos de corrosividad alta.	79
Figura 3.32 Ajuste del algoritmo a los valores de salida de U2 durante la fase de entrenamiento del sistema basado en reglas para suelos de corrosividad alta.	80
Figura 3.33 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de U2 en suelos de corrosividad alta.	82
Figura 3.34 Ajuste del algoritmo a los valores de salida de U2 durante la fase de entrenamiento del sistema basado en reglas para suelos de corrosividad alta	83
Figura 3.35 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de U3 en suelos de corrosividad alta.	84
Figura 3.36 Ajuste del algoritmo a los valores de salida de U3 durante la fase de entrenamiento del sistema basado en reglas para suelos de corrosividad alta.	85
Figura 3.37 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de B1 en suelos de corrosividad alta.	86
Figura 3.38 Ajuste del algoritmo a los valores de salida de B1 durante la fase de entrenamiento del sistema basado en reglas para suelos de corrosividad alta	86
Figura 3.39 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de B2 en suelos de corrosividad alta.	87
Figura 3.40 Ajuste del algoritmo a los valores de salida de B2 durante la fase de entrenamiento del sistema basado en reglas para suelos de corrosividad alta	88
Figura 3.41 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de B3 en suelos de corrosividad alta.	89
Figura 3.42 Ajuste del algoritmo a los valores de salida de B3 durante la fase de entrenamiento del sistema basado en reglas para suelos de corrosividad alta	90

Figura 3.43 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de IL en suelos de corrosividad alta	91
Figura 3.44 Ajuste del algoritmo a los valores de salida de IL durante la fase de entrenamiento del sistema basado en reglas para suelos de corrosividad alta	92
Figura 3.45 Perfil de potenciales calculados numéricamente y potenciales encontrados en el tramo uno de la tubería Pulín.	94
Figura 3.46 Perfil de potenciales calculados numéricamente en el primer tramo de la tubería Pulín.	95

LISTA DE TABLAS

Tabla 3.1 Parámetros de suelo normalizados utilizados durante el proceso de entrenamiento	44
Tabla 3.2 Parámetros iniciales del algoritmo genético que optimiza al sistema basado en reglas para predecir las constantes U1, U2, U3, B1, B2, B3 y IL en el grupo de suelos de baja corrosividad.	48
Tabla 3.3 Funciones de pertenencia después del proceso de entrenamiento de los suelos de baja corrosividad en la predicción del parámetro U1	49
Tabla 3.4 Sistema base de reglas borrosas para la predicción de U1 en suelos de corrosividad baja	49
Tabla 3.5 Funciones de pertenencia después del proceso de entrenamiento de los suelos de baja corrosividad en la predicción del parámetro U2.	51
Tabla 3.6 Sistema base de reglas borrosas para la predicción de U2 en suelos de corrosividad baja	52
Tabla 3.7 Funciones de pertenencia después del proceso de entrenamiento de los suelos de baja corrosividad en la predicción del parámetro U3.	54
Tabla 3.8 Sistema base de reglas borrosas para la predicción de U3 en suelos de corrosividad baja	54
Tabla 3.9 Sistema base de reglas borrosas para la predicción de B1 en suelos de corrosividad baja	56
Tabla 3.10 Sistema base de reglas borrosas para la predicción de B2 en suelos de corrosividad baja	58
Tabla 3.11 Sistema base de reglas borrosas para la predicción de B3 en suelos de corrosividad baja	60
Tabla 3.12 Sistema base de reglas borrosas para la predicción de IL en suelos de corrosividad baja	60
Tabla 3.13 Parámetros iniciales del algoritmo genético que optimiza al sistema basado en reglas para predecir las constantes U1, U2, U3, B1, B2, B3 y IL en el grupo de suelos de corrosividad media.	63
Tabla 3.14 Funciones de pertenencia después del proceso de entrenamiento de los suelos de corrosividad media en la predicción del parámetro U1.	64
Tabla 3.15 Sistema base de reglas borrosas para la predicción de U1 en suelos de corrosividad media.	64
Tabla 3.16 Funciones de pertenencia después del proceso de entrenamiento de los suelos de corrosividad media en la predicción del parámetro U2.	66
Tabla 3.17 Sistema base de reglas borrosas para la predicción de U2 en suelos de corrosividad media	67

Tabla 3.18 Funciones de pertenencia después del proceso de entrenamiento de los suelos de corrosividad media en la predicción del parámetro U3.	68
Tabla 3.19 Sistema base de reglas borrosas para la predicción de U3 en suelos de corrosividad media	69
Tabla 3.20 Sistema base de reglas borrosas para la predicción de B1 en suelos de corrosividad media.	70
Tabla 3.21 Sistema base de reglas borrosas para la predicción de B2 en suelos de corrosividad media	72
Tabla 3.22 Sistema base de reglas borrosas para la predicción de B3 en suelos de corrosividad media	74
Tabla 3.23 Sistema base de reglas borrosas para la predicción de IL en suelos de corrosividad media	75
Tabla 3.24 Parámetros iniciales del algoritmo genético que optimiza al sistema basado en reglas para predecir las constantes U1, U2, U3, B1, B2, B3 y IL en el grupo de suelos de corrosividad media.	77
Tabla 3.25 Funciones de pertenencia después del proceso de entrenamiento de los suelos de corrosividad alta en la predicción del parámetro U1.	78
Tabla 3.26 Sistema base de reglas borrosas para la predicción de U1 en suelos de corrosividad alta	78
Tabla 3.27 Funciones de pertenencia después del proceso de entrenamiento de los suelos de corrosividad alta en la predicción del parámetro U2.	80
Tabla 3.28 Sistema base de reglas borrosas para la predicción de U2 en suelos de corrosividad alta	81
Tabla 3.29 Funciones de pertenencia después del proceso de entrenamiento de los suelos de corrosividad alta en la predicción del parámetro U3.	83
Tabla 3.30 Sistema base de reglas borrosas para la predicción de U3 en suelos de corrosividad alta	83
Tabla 3.31 Sistema base de reglas borrosas para la predicción de B1 en suelos de corrosividad alta.	85
Tabla 3.32 Sistema base de reglas borrosas para la predicción de B2 en suelos de corrosividad alta	87
Tabla 3.33 Sistema base de reglas borrosas para la predicción de B3 en suelos de corrosividad alta	88
Tabla 3.34 Sistema base de reglas borrosas para la predicción de IL en suelos de corrosividad alta	90
Tabla 3.35 Parámetros fisicoquímicos del suelo en el cual se encuentra enterrado el primer tramo del ducto Pulín	93
Tabla 3.36 Parámetros iniciales del algoritmo genético que optimiza al sistema de protección catódica del primer tramo de la tubería de Pulín.	94

INTRODUCCION

La protección catódica es un método de prevención de la corrosión que utiliza las propiedades electroquímicas para asegurar que la estructura a ser protegida sea el cátodo de la celda electrolítica. Dicha técnica es empleada con frecuencia para proteger estructuras metálicas ubicadas en ambientes agresivos y es el pilar de la protección contra la corrosión en la industria del transporte de gas, petróleo y sus derivados, agua, y otros fluidos; también se utiliza para proteger estructuras valiosas como tanques de almacenamiento, barcos, y plataformas marítimas entre otras.

Colombia cuenta con un número considerable de estructuras protegidas mediante sistemas de protección catódica. En el caso particular de las tuberías de transporte de fluidos; como oleoductos, poliductos, gaseoductos, tuberías de agua, etc; la mayoría de ellas se encuentran ubicadas en suelos arcillosos principalmente, medios discontinuos por excelencia. Estas estructuras de ingeniería, valiosas y vitales para el país, se encuentran sometidas a la corrosión por suelos. Los efectos de tal fenómeno pueden producir daños catastróficos resultando en grandes pérdidas económicas, ambientales y humanas, además de sobre costos en el transporte de agua electricidad y combustibles todos ellos de alto impacto económico y social. Evaluar, predecir y mitigar el efecto que los suelos tienen sobre las estructuras metálicas es un trabajo gran relevancia e impacto en la sociedad.

La simulación de sistemas de protección catódica ha sido una preocupación prioritaria de científicos, matemáticos e ingenieros de corrosión, en 1.988 Zamani [1.] demostró que es posible simular numéricamente el comportamiento de un sistema de protección catódica de una embarcación naval considerando

el agua de mar como un medio continuo, lo que facilita su análisis y formulación numérica. Posteriormente en 1.991 Aoki y colaboradores [2.] utilizaron el método de los elementos de contorno para predecir las velocidades de corrosión sistemas galvánicos utilizando curvas de polarización experimentales como condición de frontera en lugar de considerarla como una recta. En 1.991 Lee y colaboradores [3.] utilizaron por primera vez de manera efectiva los elementos de contorno para analizar el sistema de protección catódica de una estructura geoméricamente compleja utilizando una aproximación numérica de la función de ensayo, necesaria para aplicar el método, en lugar de una analítica.

Sólo hasta 1.994 Brichau y Deconick desarrollaron un modelo matemático de un sistema de protección catódica aplicado a tuberías enterradas considerando constante la resistividad del suelo. En 1.996 Steven [5.] y colaboradores desarrollaron una metodología para optimizar la posición de los ánodos de sacrificio de sistemas de protección catódica galvánicos proponiendo una función que tomara en cuenta la distribución de potencial que producía sobre la superficie de la estructura, y en 1.999 Aoki y Amaya [6.] extendieron el trabajo de Steven a sistemas de protección catódica por corriente impresa utilizando una función de penalización que complementara la de optimización, sin embargo las optimizaciones mostraron fuerte dependencia de las suposiciones iniciales.

La búsqueda de algoritmos de optimización más robustos llevó a Aoki y Amaya [7.] a la formulación del método efectivo de elementos de contorno que evita recalcular todas las matrices en cada etapa de la optimización, disminuyendo así el tiempo de calculo; esta nueva formulación fue aprovechada por Miltiadou y Wrobel en 2.002 [8.] a sugerir la utilización de algoritmos genéticos para la optimización de sistemas de protección catódica por corriente impresa alcanzando resultados muy prometedores, aplicando la misma metodología para resolver otros problemas de optimización propios de la protección catódica [9.]. Ya en 2.005 Santana y Adey [10.] Mejoraron la capacidad de los

elementos de contorno de manejar geometrías complicadas considerando el cambio de potencial en sitios críticos como suave.

En cuanto a la curva de polarización, tradicionalmente se consideró constante en el tiempo y siempre disponible, aún cuando estas dos aseveraciones no sean del todo ciertas, hasta que en 1.999 Santiago y Telles [11] estudiaron el efecto de diversas variables sobre la curva de polarización en ambientes marinos desarrollando un método para calcularla en el tiempo. En esa misma dirección Divo y otros [12] en 2.000 estudiaron sistemas de electroplateado, y utilizando elementos de contorno estudiaron las leyes experimentales de polarización y plantearon la extensión del método a cualquier sistema electroquímico, luego en 2.001 Druesne [13] extendieron el trabajo de Divo encontrando mejores ajustes a datos experimentales. Finalmente en 2.003 Miltiadou y Wrobel [14] utilizaron algoritmos genéticos para predecir las curvas de polarización de estructuras inaccesibles a partir de experimentos potenciostáticos de las regiones adyacentes a las mismas. En el mismo año Chisholm y colaboradores estudiaron el efecto de las reacciones electroquímicas que ocurren sobre un electrodo y la manera en que afecta la curva de polarización, adicionalmente proponen una técnica para solucionar el problema planteado [15].

Aun cuando el estado del arte de la protección catódica se encuentra en un estado avanzado, todavía persisten algunos problemas prácticos por resolver principalmente en cuanto a lo referente a la curva de polarización pues como se puede apreciar en el párrafo anterior es posible predecirla para estructuras ubicadas en medios continuos [11][12][13][14][15], el problema persiste cuando se trata de medios discontinuos como es el caso de la corrosión en suelos; para estos casos la única alternativa es la consecución de curvas experimentales, las cuales no están siempre disponibles dado el alto costo que ello representaría para estructura que se extienden por cientos de kilómetros y lo inaccesible de la estructura. Es por ello que la industria del transporte de fluidos por ductos no se ha beneficiado tan ampliamente de la simulación de

protección catódica como podría hacerlo si fuese posible predecir la curva de polarización. Sin embargo revisando los trabajos de Song y colaboradores [16], donde se demostró que es posible correlacionar el comportamiento corrosivo de los suelos de acuerdo con sus propiedades fisicoquímicas haciendo uso de la matemática borrosa; al igual que Phan que en su trabajo publicado en 2002 [17], muestra la manera de tratar problemas de suelos utilizando agrupamiento difuso o borroso correlacionando múltiples variables. La matemática borrosa es un campo prometedor cuando se afronta el problema de correlacionar las variables inherentes a la corrosión de suelos las cuales interaccionan entre si de formas poco conocidas.

El resultado de la interacción del suelo, con el metal está representado por la curva de polarización, la cual es por tanto resultado de la combinación entre las características fisicoquímicas del suelo y las del metal. Es decir existe una relación entre la curva de polarización que se produce sobre un metal enterrado en un suelo y los parámetros fisicoquímicos de este último. Por otro lado el estado de polarización de un metal influenciado por parámetros cuyas interacciones son pobremente conocidas, es una tarea que puede ser resuelta utilizando las técnicas de la inteligencia artificial, como demostró Taleb y colaboradores en 2005 [18].

Partiendo de las anteriores premisas en el presente trabajo asevera que: Es posible predecir la curva de polarización de un acero enterrado AISI 1020 a partir de los parámetros fisicoquímicos del suelo, de tal forma que la curva así obtenida sea utilizada como condición de frontera de la ecuación de Laplace para el potencial que modela un sistema de protección catódica.

En otras palabras, es posible predecir la curva de polarización del acero, utilizando matemática borrosa, a partir de datos fisicoquímicos del suelo en el que está enterrado. Esta curva puede ser implementarla en la solución de la ecuación de Laplace para el potencial utilizando elementos de contorno y así

optimizar la configuración del sistema de protección catódica por algoritmos genéticos.

La curva de polarización está parametrizada por siete constantes, resulta evidente que es imposible correlacionar de manera sencilla cada uno de estas constantes con todos los valores de los parámetros fisicoquímicos de los suelos (contenido de carbonatos, sulfatos, cloruros, agua, pH, resistividad, etc.) es por ello que en este trabajo se realiza un agrupamiento borroso de los suelos de acuerdo con su corrosividad. Este agrupamiento difiere de la simple clasificación, pues permite agrupar los suelos en clusters que relacionen sus propiedades y la forma en que afecta la corrosividad [16]. Posterior a este agrupamiento borroso se correlacionan las variables del suelo con los parámetros de la curva de polarización, para ello se hace uso de sistemas basados en reglas borrosas. Estos sistemas permiten representar la ambivalencia de la realidad y han demostrado predecir comportamientos complejos a partir de reglas muy simples. Para la selección del conjunto de reglas óptimo y de las funciones de pertenencia que representan los universos de las diferentes variables, se utiliza un algoritmo genético.

Una vez culminado los procesos de agrupamiento, y el de formulación y optimización del sistema basado en reglas borrosas, ya se puede contar con la curva de polarización para un suelo problema o para uno conocido cuando alguna de sus características varíe. Esta curva así obtenida se utiliza como condición de frontera en la solución de la ecuación parcial que modela el problema; e iterativamente se obtienen los valores óptimos de corriente y posición de los ánodos por medio de un algoritmo genético.

Los resultados obtenidos deberán ser validados con datos frescos provenientes de suelos a los cuales se conocen sus características y el comportamiento del acero enterrado en ellos.

1. MARCO TEORICO

La protección catódica es uno de los métodos más ampliamente utilizados para prevenir la corrosión. Puede reducir o prevenir la corrosión de cualquier metal expuesto a un ambiente agresivo. Los sistemas de protección catódica encuentran su mayor uso en los aceros al carbono, extendiendo la vida útil de cientos de kilómetros de tuberías de acero, estructuras a mar abierto, cascos de buques, tanques de agua y de algunos equipos químicos.

La protección catódica tiene por objetivo hacer que la estructura a ser protegida alcance un potencial tal que sea imposible que las reacciones anódicas tengan lugar.

Para poder diseñar un sistema de protección catódica se requiere el conocimiento de la distribución de la densidad de corriente y potencial electroquímico sobre la superficie del metal, que produce una disposición determinada de ánodos de corriente impresa. El primer paso obvio es la formulación de un modelo matemático del problema para luego enfocarse en la solución numérica del mismo.

1.1. Modelo Numérico de la Protección Catódica

Los sistemas de protección catódica son generalmente utilizados para proteger estructuras tales como barcos, tanques y tuberías que se encuentra emplazada en un medio agresivo bien sea el mar, agentes químicos y suelos entre otros;

en estado estable el problema puede ser descrito matemáticamente partiendo de la ecuación de Nernst – Planck para la transferencia de masa en un electrodo gobernada por la transferencia de masa [19].

$$\mathbf{J} = -F \sum_{k=1}^N z_k D_k \nabla c_k - F^2 \sum_{k=1}^N z_k^2 c_k u_k \nabla U + \sum_{k=1}^N c_k v_k \quad (1.1)$$

Donde \mathbf{J} es el vector densidad de corriente, F la constante de Faraday, z_k , c_k , u_k , v_k y D_k son la carga, concentración, movilidad mecánica, velocidad y coeficiente de difusión respectivamente para las especies k , N es el número de especies y U es el potencial electroquímico. Definiendo la conductividad del electrolito de la forma

$$\sigma = -F^2 \sum_{k=1}^N z_k^2 c_k u_k \quad (1.2)$$

La ecuación 1.1 se reduce a

$$\mathbf{J} = -F \sum_{k=1}^N z_k D_k \nabla c_k - \sigma \nabla U + \sum_{k=1}^N c_k v_k \quad (1.3)$$

El primer término de la ecuación corresponde a la porción de la corriente que es sostenida por gradientes de concentración, y que es generalmente despreciado en simulaciones a gran escala debido a que tienen principal influencia sobre la capa de difusión, cercana a la estructura, la cual es muy pequeña comparada con las dimensiones del problema y sus efectos son incorporados en las curvas de polarización aplicadas como condiciones de frontera. El tercer término corresponde al componente de la densidad de corriente que depende de la convección y se incorpora cuando el electrolito se encuentra en movimiento relativo a la estructura. La densidad de corriente está entonces dada por.

$$\mathbf{J} = -\sigma \nabla U \quad (1.4)$$

La cual es la ecuación descrita por la Ley de Ohm. la conservación de carga requiere que la derivada sea nula, adicionalmente si se considera la conductividad constante se obtiene [20].

$$\nabla^2 U = 0 \quad (1.5)$$

De esta forma la ecuación de Nernst – Planck se reduce a la ecuación de Laplace para el potencial electroquímico U.

1.1.1 Condiciones de Frontera

En superficies aisladas la densidad de corriente en la dirección normal es igual a cero.

$$J_n = -\sigma \frac{\partial U}{\partial n} = 0 \quad (1.6)$$

La misma condición se aplica para la interface aire – suelo. La estructura a ser protegida está sometida a una condición de frontera no lineal que sería la curva de polarización, y los ánodos de corriente impresa tendrán una densidad de corriente definida.

En condiciones normales no es sencillo obtener una expresión cerrada para las curvas de polarización a partir de los datos obtenidos experimentalmente de ensayos potenciostáticos, las curvas de polarización deberán ser colocadas directamente dentro de los códigos mediante algún tipo de interpolación entre los puntos discretos. También es posible ajustar los datos experimentales a el modelo teórico descrito por la ecuación de Taffel o Butler – Volmer.

$$J = e^{(U-U_1)/B_1} - \left(\frac{1}{i_L} + \frac{1}{e^{(U-U_2)/B_2}} \right)^{-1} - e^{-(U-U_3)/B_3} \quad (1.7)$$

Donde U_i , B_i $i=1,2,3$, representan el potencial y las pendientes Tafel para la oxidación del hierro, reducción del oxígeno y evolución de hidrógeno respectivamente y i_L la corriente límite del oxígeno, pero es común tomarlas como constantes positivas que sirven para ajustar la curva.




Figura 1.1 Condiciones de Frontera de la protección Catódica

Finalmente la corriente es conocida para cada electrodo de corriente impresa.

1.2. Método de los elementos de Contorno en la Protección Catódica

Para resolver la ecuación de Laplace es necesario hacer uso de técnicas especiales debido a que la solución es altamente dependiente de la forma del dominio, entre la estantería de métodos utilizados para resolver numéricamente ecuaciones diferenciales parciales se encuentran las diferencias finitas, los elementos finitos y los elementos de contorno; estos últimos ofrecen una alternativa efectiva de solución para los sistemas de protección catódica puesto que reducen en uno las dimensiones del problema restringiendo la discretización a la frontera del mismo, lo que es particularmente útil en

problemas electroquímicos donde la mayoría de los fenómenos tienen lugar sobre la superficie del metal.

La ecuación integral de contorno correspondiente para la ecuación de Laplace es obtenida utilizando la tercera identidad de Green en la forma de la ecuación.

$$C(P)U(P) + \int_{\Gamma} U(\chi) \frac{\partial U^*(\chi, P)}{\partial n} d\Gamma = \int_{\Gamma} U^*(P, \chi) \frac{\partial U(\chi)}{\partial n} d\Gamma \quad (1.8)$$

Siendo $C(P)$ una constante dependiente de la forma P del nodo en consideración, $U(\chi)$ y $J(\chi)$ el potencial electroquímico y la densidad de corriente respectivamente evaluadas sobre el contorno del problema, y $U^*(P, \chi)$ y $\partial U^*(P, \chi)/\partial n$ la función de prueba y su derivada evaluada sobre el contorno del problema con respecto al nodo en consideración, Se elige por conveniencia como función de prueba una solución fundamental del problema en el espacio libre [6].

Rescribiendo la ecuación teniendo en cuenta que la derivada parcial del potencial en la dirección normal es la corriente eléctrica

$$C(P)U(P) + \int_{\Gamma} U(\chi) J^*(P, \chi) d\Gamma = \int_{\Gamma} U^*(P, \chi) J(\chi) d\Gamma \quad (1.9)$$

Discretizando la ecuación integral de contorno y aplicándola contorno sobre todos los N elementos de la frontera Γ , se forma un sistema de ecuaciones.

$$HU = GJ \quad (1.10)$$

Donde H y G son las matrices de los coeficientes de influencia, y U e I los vectores de los valores nodales de el potencial y la densidad de corriente respectivamente. Debido a las condiciones de frontera no lineales, representadas por la curva de polarización debe resolverse el sistema de

ecuaciones no lineales resultante por un método iterativo del tipo Newton – Raphson.

Para dominios infinitos la ecuación integral de contorno (1.9) es escrita para región finita rodeada por una esfera cuyo radio R tiende a infinito.

$$C(P)U(P) + \int_{\Gamma} U(\chi)J^*(P, \chi) - U^*(P, \chi)J(\chi)d\Gamma + \lim_{R \rightarrow \infty} \int_{\Gamma R} U(\chi)J^*(P, \chi) - U^*(P, \chi)J(\chi)d\Gamma \quad (1.11)$$

En el caso presente $U = U_{\infty}$ y $J = 0$ en el infinito, de tal manera que la ecuación anterior se reduce a

$$C(P)U(P) + \int_{\Gamma} U(\chi)J^*(P, \chi) - U^*(P, \chi)J(\chi)d\Gamma + U_{\infty} \quad (1.12)$$

Para cualquier punto P en la región interna. El problema matemático es complementado con la condición de frontera proveniente de la condición de equilibrio que garantiza que no hay pérdida y acumulación de corriente en el sistema.

$$\int_{\Gamma} J(\chi)d\Gamma = 0 \quad (1.13)$$

Esta última condición complementaria es muy importante en la solución de problemas electroquímicos y no es reemplazable por $U = 0$ en el infinito lo que conduciría a resultados erróneos [2].

1.3 Optimización de Protección Catódica

El diseño de un sistema de protección catódica por corriente impresa optimo es una tarea ardua que debe considerar diversos tópicos como la óptima

localización y corriente de los electrodos que provean un adecuada distribución de potencial sobre la estructura a ser protegida utilizando el mínimo consumo de electricidad.

Es evidente que la optimización de la protección catódica por corriente impresa requiere la formulación de un problema inverso, este problema resultante podrá ser resuelto utilizando algoritmos genéticos, técnica que ha demostrado ser útil y robusta para resolver problemas inversos en la protección catódica [4].

1.3.1 Algoritmos Genéticos

Los algoritmos genéticos son técnicas de búsqueda del tipo evolucionarias que emulan el proceso de selección natural en la forma en que progresan hacia un óptimo [5]. Los algoritmos genéticos han sido utilizados exitosamente en diversos problemas de optimización de protección catódica. Las ventajas en comparación con los procedimientos clásicos pueden son resumidas a continuación

- La optimización es llevada a cabo sólo mediante la evaluación de la función objetivo.
- No se requiere que la función objetivo sea continua.
- No se requiere evaluar la derivada de la función objetivo.
- Puesto que la técnica se basa en la optimización de operadores aleatorios en cada generación, existe una alta probabilidad de encontrar un mínimo global.

El algoritmo parte de un conjunto inicial de configuraciones aleatorias llamado población con un tamaño o número de individuos definido, cada individuo o cromosoma es una posible solución al problema; en el caso de la protección catódica la información genética de cada individuos representaría una posible configuración del sistema que incluiría la posición y corriente de los electrodos de corriente impresa. Durante cada iteración o generación, los individuos de la

población actual son evaluados mediante alguna medida de adaptación que valorará que tan buena solución es o de otra forma que tan adaptado está el individuo. Basado en la medida de adaptación algunos individuos de la población correspondiente a la generación actual son seleccionados para ser los padres de la siguiente iteración o generación futura, de tal forma que los individuos mejor adaptados tendrán mayores posibilidades de ser escogidos como padres. Entonces serán aplicados un conjunto de operadores genéticos sobre los padres previamente seleccionados dando lugar a una nueva generación llamada descendencia.

Los operadores genéticos combinan las características de los padres, los más comunes son el cruce y la mutación. El operador cruce permite combinar la información genética de los mejores individuos en una nueva descendencia. La aplicación de esta operación necesita de la selección de una posibilidad de cruce aleatoria, la obtención de las parejas de individuos y de un número aleatorio que indique una posición en el vector binario que representa a un cromosoma, esta posición será el punto de cruce, el operador actúa copiando la información genética del primer padres antes del punto de cruce y la del segundo después del él. Los valores típicos del punto de cruce están en el rango de 0.7 a 0.9. Después de realizado el cruce tiene lugar la mutación, esto previene que todas las soluciones converjan a un mínimo local.

El proceso de mutación incluye la generación de un número aleatorio para cada bit de la información genética correspondiente al individuo, si este número es mayor que la probabilidad de mutación definida al inicio del problema el bit será mutado, la mutación puede realizarse bit a bit o simplemente cambiar todos los bit de 1 a 0 o viceversa.

Después de que los operadores de selección, cruce y mutación fueron aplicados a una población, la nueva descendencia está lista y el contador generacional es incrementado en uno. Estas operaciones se realizarán sobre

cada generación hasta que el criterio de convergencia sea satisfecho o se llegue a un número de generaciones o iteraciones previamente establecido

En el caso particular de la protección catódica el objetivo de la optimización es la superficie de la estructura a ser protegida alcance un potencial igual o inferior al potencial de protección U_p el cual asegura que la estructura estará protegida contra la corrosión, por lo general U_p es tomado como -850mV.

$$U \leq U_p \quad (1.14)$$

Desde el punto de vista de ingeniería, el problema es determinar la posición y corriente óptima de los electrodos para que el criterio de protección sea alcanzado requiriendo el mínimo consumo de energía. El consumo de energía está dado por.

$$P = \sum_{e=1}^N \int_{\Gamma_e} (U_e + f_e(J_e)) J_e d\Gamma \quad (1.15)$$

Donde el subíndice e denota que los electrodos de corriente impresa y N es el número total de electrodos, Por tanto el problema a considerar es minimizar la ecuación (1.15) sometida a la condición (1.14), donde U y J deben satisfacer las ecuaciones (1.5) a (1.7) [4].

1.4. Predicción de la Curva de Polarización

En la simulación de protección catódica es de vital importancia contar con conocimiento del estado de polarización del metal en suelo. La curva de polarización ofrece una relación matemática entre las dos principales variables, corriente y potencial, esta correspondencia es ofrecida mediante una ecuación altamente no lineal, ecuación (1.7). El principal problema radica en que esta curva sólo puede ser obtenida mediante ensayos potensiométricos y frecuentemente no se cuenta con ella, adicionalmente, su comportamiento es

variable en el tiempo pues depende de los cambios en el suelo tales como contenido de agua y de otras especies químicas así como de la actividad bacteriana. Contar con una metodología que posibilite la predicción de la curva de polarización a partir de parámetros fisicoquímicos del suelo representa un adelanto relevante en el análisis del comportamiento de sistemas de protección catódica de estructuras enterradas. Para alcanzar este conocimiento es necesario acudir a herramientas como el agrupamiento difuso, la lógica difusa y la generación automática de reglas borrosas tipo Mandami.

El primer paso lógico para la predicción de la curva es el agrupamiento del suelo según su corrosividad en función de sus características fisicoquímicas.

Evaluar y predecir el efecto que un suelo tiene sobre una estructura metálica es un arduo, pues la corrosividad del suelo y el comportamiento del metal ante este dependen de muchos factores que interactúan de formas complejas y a menudo desconocidas. El agrupamiento difuso ha demostrado eficacia al abordar problemas de clasificación de suelos según su corrosividad [6].

Para cada categoría de suelo se puede encontrar un conjunto de reglas If ... Then de lógica difusa tales que permitan el cálculo de los parámetros de la curva de polarización descrita por la ecuación (1.7), la búsqueda de tales reglas debe ser realizada automáticamente utilizando algoritmos genéticos [9] [10].

1.4.1 Agrupamiento Difuso

Se denomina agrupamiento al método mediante el cual se agrupan un conjunto de especímenes en un número de subconjuntos llamados clusters. La principal diferencia entre el agrupamiento y la clasificación radica en que en la primera se desconoce a priori que características tendrán los clusters, estos serán contruidos basados en medidas de la diferencia o similitud entre los especímenes, mientras que en la clasificación es necesario conocer de antemano la información concerniente a los clusters, el algoritmo decidirá

posteriormente si los sujetos pertenecen o no a un subconjunto dado. El algoritmo de agrupamiento difuso permite que un espécimen pertenezca en algún grado a varios clusters al tiempo.

Si el problema consta de n especímenes, cada uno de ellos constituido por m parámetros, el espacio espécimen podrá ser construido

$$X' = (x'_{ij})_{nm} \quad (1.16)$$

$$i=1,2,\dots,n; j=1,2,\dots,m$$

Debido a que diferentes parámetros poseen distintas escalas, es necesario eliminar la influencia de estas escalas sobre el análisis de agrupamiento normalizando los especímenes. Normalmente se utiliza una de tres posibles estrategias de normalización.

Primera estrategia.

$$x_{ij} = \frac{x'_{ij} - \gamma_j}{\delta'_{ij}} \quad (1.17)$$

Donde

$$\gamma_j = \left(\frac{1}{n} \right) \sum_{i=1}^n x'_{ij} \quad (1.18)$$

$$\delta'_{ij} = \left[\frac{\sum_{i=1}^n (x'_{ij} - \gamma_j)^2}{n-1} \right]^{1/2} \quad (1.19)$$

Segundo método de normalización.

$$X_{ij} = \frac{x'_{ij} - (x'_{ij})_{\min}}{(x'_{ij})_{\max} - (x'_{ij})_{\min}} \quad (1.20)$$

Donde

$$(x'_{ij})_{\max} = \max_{i=1}^n(x'_{ij}) \quad (1.21)$$

$$(x'_{ij})_{\min} = \min_{i=1}^n(x'_{ij}) \quad (1.22)$$

Y por último

$$X_{ij} = \frac{x'_{ij} - \gamma_j}{(x'_{ij})_{\max} - (x'_{ij})_{\min}} \quad (1.23)$$

Una vez se ha realizado el pretratamiento de los datos, se obtiene un nuevo espacio espécimen normalizado.

Sobre la base de este nuevo espacio se puede llegar a cabo el agrupamiento, este comienza determinando la similaridad o disimilaridad entre los especímenes utilizando una función de disimilaridad, informalmente denominada distancia d_{pq} , donde d es el indicador de similaridad entre cualesquiera dos especímenes p y q . Adicionalmente d_{pq} cumple con las siguientes propiedades.

$$d_{pq} = 1 \text{ (Auto retorno) Cuando } p = q \quad (1.24)$$

$$d_{pq} = d_{qp} \text{ (Simetría) Cuando } p \neq q \quad (1.25)$$

d es llamado una métrica, existen docenas de funciones de similaridad que pueden ser utilizadas para un análisis difuso: distancia Euclideana, Manhattan, Theodoridis, producto interno, etc. La elección de la función de similaridad dependerá de los resultados que se esperen. En muchos problemas el efecto de las variables sobre los resultados no es conocido, en otros está sujeto a investigación; por consiguiente la mejor función de similaridad debe ser

determinada por ensayo y error, así en ocasiones diferentes funciones de similaridad producen diferentes agrupamientos.

Una vez elegida la función de similaridad más conveniente, se obtiene la matriz de similaridad $R = (d_{pq})_{nn}$. Esta matriz posee propiedades de simetría y auto retorno pues está sujeta a las condiciones (1.24) y (1.25), sin embargo carece de transmitividad y debe ser transformada en una matriz equivalente para poder utilizarla en agrupamiento difuso $R^* = (d^*_{pq})_{nn}$. La manera de transformar la matriz de similaridad en una equivalente es realizando la multiplicación difusa repetidamente la matriz de similaridad. La multiplicación difusa es una operación diferente a la multiplicación matricial convencional y esta definida así.

$$R \times R = R^2 = R \otimes R = (C_{ij})_{nn} \quad (1.26)$$

Donde

$$(C_{ij})_{nn} = \min_{k=1}^{n-1} \left[\max_{k=1}^n (d_{ik}, d_{kj}) \right] \quad (1.27)$$

De acuerdo con la teoría del agrupamiento difuso, si la multiplicación anterior se realiza al menos K veces, entonces la matriz de similaridad se convertirá en una equivalente R^* .

$$R \rightarrow R^2 \rightarrow R^4 \rightarrow R^8 \rightarrow \dots R^{2^K} = R^* \quad (1.28)$$

Donde K es un número entero positivo determinado por el número de especímenes n, de acuerdo con la relación.

$$2^{K-1} < n \leq 2^K \quad (1.29)$$

$$K - 1 < \log_2 n \leq K \quad (1.30)$$

O de otra manera

$$\log_2 n < K \leq (1 + \log_2 n) \quad (1.31)$$

Una vez determinado R^* , se selecciona un valor de corte λ adecuado que resulta en.

$$e_{ij} = 1 \quad \text{Si } d_{ij}^* \geq \lambda \quad (1.32)$$

$$e_{ij} = 0 \quad \text{Si } d_{ij}^* < \lambda \quad (1.33)$$

con el valor de e_{ij} es posible calcular el corte λ de la matriz R^* obteniendo la matriz $E_\lambda = (e_{ij})_{nn}$ y todos los especímenes con un valor de $e_{ij} = 1$, tanto el espécimen i como el j , serán agrupados en un cluster.

Se debe notar que λ refleja el grado de similaridad de los especímenes agrupados en un cluster. Entre mayor sea λ , más alto será el grado de similaridad de los especímenes de un grupo y más cercana la relación entre ellos, sin embargo la selección del criterio λ es teóricamente arbitrario. Es posible elegir diversos valores para λ entre 0 y 1, pero distintos valores de λ conducirán a diferentes valores de E_λ y como resultado de ello se producirán distintas agrupaciones. De modo que determinar el valor adecuado de λ es una actividad crítica dentro de el proceso de agrupamiento difuso. Usualmente es necesario realizar un entrenamiento para obtener un λ satisfactorio; por ejemplo escoger especímenes típicos y determinar experimental o teóricamente el número de categorías y a cual pertenece cada espécimen, luego mediante ensayo y error se determinan los valores de λ para cada grupo de tal forma que los resultados coincidan con los esperados, si no es posible determinar valores de corte que satisfagan las condiciones iniciales, se debe cambiar de funciones de similaridad hasta lograr los clusters deseados.

En el caso del agrupamiento de suelos con respecto al comportamiento de un metal en ellos, es razonable categorizarlos según su corrosividad, entonces por ejemplo, si se tienen n suelos definidos como los especímenes S_1, S_2, \dots, S_n , cada uno de ellos caracterizados por m parámetros P_1, P_2, \dots, P_m , y adicionalmente se conocen los valores de corrosividad de ellos (alta, media o baja corrosividad), estos suelos podrán ser agrupados en tres clusters. Siguiendo el procedimiento de agrupamiento difuso, se obtienen el espacio espécimen y el normalizado. Seguidamente se conforma la matriz de similaridad utilizando una función de similaridad de prueba y a continuación se transforma en la matriz equivalente. Mediante ensayo y error se eligen una serie de valores de λ y se calculan las matrices de corte y finalmente se clasifican los suelos. Si por ejemplo se elige $\lambda=0$, obviamente, todos los suelos serán agrupados en un solo cluster, pero el resultado no será útil, ciertamente si $\lambda=1$, se formarán n clusters cada uno con un miembro. Siguiendo este razonamiento λ deberá decrecer hasta que todos los suelos de baja corrosividad sean correctamente agrupados en un cluster y se tomará el valor de λ como λ_B . Este proceso de ensayo y error se repite y se obtienen los valores de corte λ_M y λ_A para los suelos de corrosividad media y alta respectivamente [6].

La selección de λ en el proceso de entrenamiento no sólo verifica el hecho que existe una relación difusa entre las características del suelo y la corrosividad, sino que también provee la base para la predicción de la corrosividad y la clasificación de un nuevo suelo a partir de sus parámetros fisicoquímicos característicos.

1.4.2 Predicción de la curva de polarización por lógica borrosa

La tener los suelos categorizados en clusters, se pueden encontrar, para cada categoría, un conjunto de reglas If ... Then tipo Mandami de lógica difusa tales que permitan el calcular las constantes de la curva de polarización descrita por

la ecuación (1.7) a partir de los parámetros fisicoquímicos del suelo en cuestión.

1.4.2.1 Lógica borrosa

La lógica borrosa o difusa se puede inscribir en el contexto de la Lógica Multivaluada. A diferencia de la lógica clásica bivaluada, que sólo toma valores de cierto 1 y falso 0, la Lógica difusa opera en un rango de valores identificados mediante números racionales en el intervalo $[0, 1]$.

Uno de los objetivos de la Lógica Borrosa es proporcionar las bases del razonamiento aproximado que utiliza premisas imprecisas como instrumento para formular el conocimiento.

La lógica difusa opera sobre los conjuntos difusos, que en contraposición de los conjuntos clásicos que asignan el valor 0 ó 1 a cada elemento para indicar la pertenencia o no a dicho conjunto, los conjuntos borrosos o difusos asignan a los elementos una función, de forma que los valores asignados a los elementos del conjunto caigan en un rango particular, y con ello indiquen el grado de pertenencia de los elementos al conjunto en cuestión. Esta función se llama función de pertenencia y el conjunto por ella definida Conjunto Borroso o difuso. La función de pertenencia μ_A por la que un conjunto borroso A se define, siendo $[0, 1]$ el intervalo de números reales que incluye los extremos, tiene la forma:

$$\mu_A = X \rightarrow [0, 1] \quad (1.34)$$

Es decir, mientras que en un conjunto clásico los elementos pertenecen o no pertenecen a él totalmente (por ejemplo un número puede pertenecer o no al conjunto de los pares, pero no pertenecerá con un determinado grado), en los

conjuntos borrosos hay grados de pertenencia en referencia a un universo local.

Junto con la idea de los conjuntos borrosos surgen las operaciones básicas entre ellos. Parecido a las operaciones sobre conjuntos booleanos también es posible interseccionar, unificar y negar conjuntos borrosos. De tal forma que por ejemplo el operador mínimo sustituye a la intersección y el operador máximo a la unión de dos conjuntos borrosos [9]. Es posible emplear los conjuntos borrosos para representar el conocimiento mediante términos imprecisos mediante reglas del tipo *Si x_1 es $A_{1,1}$ y/o x_2 es $A_{2,1}$ y/o x_n es $A_{1,n}$ Entonces y es B_1* . Cada variable que interviene como hipótesis en un regla tiene asociado un dominio. Cada dominio puede estar dividido en tantos conjuntos borrosos como se considere oportuno. Cada una de estas particiones tiene asociada una etiqueta lingüística.

Una de las ventajas de representar el conocimiento de forma difusa, radica en el aprovechamiento de ellas en el razonamiento aproximado. En el razonamiento aproximado al igual que la lógica clásica, se pueden considerar las premisas como inductoras de subconjuntos de mundos posibles que las satisfacen, aunque en el caso de la teoría del razonamiento aproximado esos conjuntos serán subconjuntos borrosos. La inferencia en ambos sistemas está basada en una regla de inclusión: una hipótesis se infiere de una colección de premisas si el subconjunto de mundos posibles que satisfacen la conjunción de las premisas está contenido en el subconjunto de mundos posibles que satisfacen la hipótesis.

La contribución fundamental del razonamiento aproximado es el uso que hace de las variables y la representación de las proposiciones en términos de verdad lingüísticos – subconjuntos borrosos - como valores de esas variables. La lógica clásica sólo usa de modo implícito el concepto de variable, en el sentido de valor de la verdad asociado a una proposición. Sin embargo la naturaleza binaria le permite ocultar este hecho.

1.4.2.2 Sistemas Basados en Reglas Difusas

Un sistema basado en reglas borrosas consiste en K reglas difusas de la forma.

$$K: \text{IF } x_1 \text{ es } I_{1,k} \text{ AND } x_2 \text{ es } I_{2,k} \text{ AND } x_3 \text{ es } I_{3,k} \text{ AND } \dots x_n \text{ es } I_{n,k} \text{ THEN } y \text{ es } O_k \quad (1.35)$$

Donde $x_1 \dots x_n$ e y representan las variables de entrada y salida e $I_{1,k}, \dots, I_{n,k}$ sus respectivas funciones de pertenencia. Entonces la extensión para la cual la regla es activada es calculada según.

$$\alpha_k = \mu_{I_{1,k}}(x_1) \text{ AND } \mu_{I_{2,k}}(x_2) \text{ AND } \dots \text{ AND } \mu_{I_{n,k}}(x_n) \quad (1.36)$$

Donde $\mu_{I_{i,k}}(x_i)$ es valor que la función de pertenencia $I_{i,k}$ toma para x_i . El resultado de la combinación de AND es utilizada como una medida de la veracidad de la regla y se aplica como la norma T mínimo. Cuando la regla se activa con un valor de verdad de α_k , el proceso de inferencia ajusta la función de pertenencia de la salida del proceso así.

$$\mu_{O_k}^{\text{inf}}(y) = \alpha_k \text{ AND } \mu_{O_k}(y) \quad (1.37)$$

El cual es el resultado de la regla difusa, en este caso el operador mínimo es utilizado como un AND.

La salida total del conjunto difuso es calculada mediante la regla composicional de inferencia.

$$\mu_O^{\text{total}}(y) = \mu_{O_1}^{\text{total}}(y) \text{ OR } \mu_{O_2}^{\text{total}}(y) \text{ OR } \dots \text{ OR } \mu_{O_k}^{\text{total}}(y) \quad (1.38)$$

Se supone que el sistema está descrito por K reglas. Para obtener una salida clásica debe usarse algunos de los métodos de defuzificación disponible.

1.4.3 Generación Automática de Reglas Base de Lógica Difusas

Para un algoritmo de aprendizaje automático que aprende la función $f: X \rightarrow Y$ y la estructura de la regla difusa base, las variables de entrada y de salida así como las funciones de pertenencia del sistema basado en reglas borrosas, necesita de una función que represente la complejidad del problema, esta función se le denomina: Función de costo de complejidad, E. En un sistema basado en reglas difusas con k reglas, n variables lingüísticas, $k \cdot n$ subpremisas y $m = m_1 + m_2 + \dots + m_n$ funciones de pertenencia es menos complejo que uno con:

1. $k+1$ reglas difusas, $k \cdot n$ subpremisas y m funciones de pertenencia
2. k reglas difusas, $(k \cdot n) + 1$ subpremisas y m funciones de pertenencia
3. k reglas difusas, $k \cdot n$ subpremisas y $m+1$ funciones de pertenencia

El peso de los anteriores tres términos depende de su aplicación y está definida por una función de costo E. Sobre la base de esta función de costo se describe un procedimiento de aprendizaje de dos pasos. El primero un, *paso de apertura* es cualquiera operación sobre el sistema basado en reglas difusas que incrementa la función de costo E. El segundo *paso de cierre* que es cualquiera operación que disminuya la función E.

En la búsqueda de un óptimo es necesario definir lo que es el sistema difuso mínimo. Aproximando un sistema real $f(\vec{x})$, utilizando un sistema difuso $X(\vec{x})$ y sea $\varepsilon > 0$ el máximo error permitido. Un sistema difuso X con $\sup \{ |f(\vec{x}) - X(\vec{x})| \mid \vec{x} \in U \} \leq \varepsilon$ es llamado mínimo sino existe otro sistema difuso Y con $\sup \{ |f(\vec{x}) - Y(\vec{x})| \mid \vec{x} \in U \} \leq \varepsilon$ y $E(y) < E(x)$, donde E es la función de costo de complejidad.

Por otro lado si se aproxima un sistema real $f(\vec{x})$, usando un sistema difuso $X(\vec{x})$ y sea $\varepsilon > 0$ el máximo error aceptado. Un sistema borroso X con $\sup\{ |f(\vec{x}) - X(\vec{x})| \mid \vec{x} \in U \} \leq \varepsilon$ es llamado mínimo si no existe otro sistema borroso Y con $\sup\{ |f(\vec{x}) - Y(\vec{x})| \mid \vec{x} \in U \} \leq \varepsilon$ y $E(Y) < E(X)$, donde E es la función de complejidad de costo.

Alternativamente es posible utilizar la distancia euclidiana absoluta.

Una vez se tiene el sistema basado en reglas borrosas dimensionado, es posible optimizarlo utilizando un planteamiento estándar de resolución de problemas inversos por medio de algoritmos genéticos, donde las soluciones serán codificadas en los cromosomas y se aplican operadores genéticos para producir nuevas soluciones y ajustarlas según el comportamiento de la función de prueba.

Cada cromosoma S contiene todos los parámetros m_{ij} y σ_{ij} donde $i=1,2,3,..,n+m$ es el número de variables y $j=1,2,3,..,q_n$ es el número de las funciones de pertenencia respectiva para cada variable.

m_{ij} y σ_{ij} son las funciones de pertenencia promedio y sigma gaussiano. Son contruidos a partir de la de las funciones de densidad de probabilidad mediante $\mu_{ij} = \lambda p(x)$. La constante λ es calculada utilizando la restricción $\sup \mu = 1$. La distribución de densidad de probabilidad es elegida según $\mu(x) = \sigma \sqrt{2\pi} \varphi(x; m, \sigma^2)$ debido a que esta distribución se ajusta muy bien a la mayoría de los problemas reales. Por tanto, las funciones de pertenencia usadas en el sistema son definidas por:

$$\mu(x) = \sigma \sqrt{2\pi} \varphi(x; m, \sigma^2) = \exp\left(-\frac{(x - m)^2}{2\sigma^2}\right) \quad (1.39)$$

Las funciones de pertenencia están limitadas por la condición $\mu(x) = 0$ cuando $x \notin [m - 2.9\sigma, m + 2.9\sigma]$. Las funciones de pertenencia no simétrica que consiste en dos funciones de pertenencia (σ_{der} y σ_{izq}) cada una definida a un lado de un punto central. Las funciones de pertenencia triangulares o trapezoidales son casos especiales de funciones de pertenencia gaussianas mediante una aproximación con dos o tres líneas. La longitud de la cadena es $L = 2 \times 1 \times (n \times m) \times k$ para el caso de las simétricas y $L = 3 \times 1 \times (n \times m) \times k$ para el caso de las no simétricas.

La función de adaptación tiene dos restricciones. La primera parte considera el comportamiento entrada/salida y la segunda parte la estructura y complejidad del sistema borroso resultante. La parte estructural de la función de adaptación tiene tres componentes.

$$OF = OF^{I/O} \times (OF^E \times OF^S \times OF^{uz}) \quad (1.40)$$

Donde OF es la función objetivo del algoritmo genético, $OF^{I/O}$ la parte de la función objetivo que considera las entradas/salidas, $OF^{I/O}$ la que toma en cuenta la estructura, $OF^{I/O}$

Sólo la función de las entradas y salidas es maximizada utilizando el recíproco del cuadrado del error.

$$OF^{I/O} = \frac{pv}{\sum_{i=1}^{pv} \sum_{j=1}^{n_{out}} (r_{i,j} - o_{i,j})^2} \quad (1.41)$$

Donde pv es el pares de datos referenciados, n_{out} la dimensión del vector de salida, o_{ij} es el valor de salida actualmente computado por el sistemas basado en reglas borrosas, r_{ij} es el respectivo valor de referencia ($i=1,2,\dots,pv$;

$j=1,2,\dots, n_{out}$) los criterios para evaluar las entradas Vs salidas deben ajustarse al tipo de problema que se está solucionando.

En la función de adaptación se consideran tres criterios de estructura para el sistema basado en reglas borrosas, el primero de ellos OF^E está relacionado con el grado de borrosidad de la entropía del sistema, y está definido por el promedio del número de reglas activadas.

$$R_{\phi} = \frac{1}{pv} \sum_{i=1}^{pv} R_{curr,i} \quad (1.42)$$

Donde $R_{curr,i}$ es el número de reglas activadas para el i -ésimo par de entrada/salida y pv el número de pares. Si el número de reglas activadas es mínimo, el sistema es más comprensible por los humanos. Para disminuir la entropía de un sistema, es necesario definir el número máximo de reglas posibles R_{max} y el número deseado de reglas borrosas activadas R_{act} , entonces es posible definir el primer componente de la función de adaptación correspondiente a la estructura.

$$OF^E = \frac{1}{\left(\frac{R_{\phi}}{R_{max}} - 1\right)a + \left(\frac{R_{\phi}}{R_{act}} - 1\right)b + 1} \quad (1.43)$$

Donde a y b son factores de peso predefinidos.

El segundo criterio para la estructura OF^S es el número de funciones de pertenencia. Para que se puedan contabilizar funciones de pertenencia con un alto grado de solapamiento, los pares de funciones de pertenencia cercanamente iguales son deseables debido a que pueden ser unificadas lo que reduce la función de costo. El criterio para el mayor número posible de funciones de pertenencia similares es:

$$\text{Of}^S = \left(\frac{s_{\text{no}}}{(n+m)R_{\text{total}}} \right) \gamma + 1 \quad (1.44)$$

Donde s_{no} es el número de funciones de pertenencia similares, $n+m$ es el total de variables de entrada y salida, R_{total} es el número total de reglas y γ un número real que actúa como factor de peso predefinido

El tercer criterio de estructura tiene que ver con las funciones de pertenencia que nunca han sido activadas ($\mu(x) = 0, \forall x \in U$) y las completamente activadas ($\mu(x) = 1, \forall x \in U$); de manera que una subpremisa que está siempre activa para todos los pares de entrenamiento, puede ser eliminada disminuyendo la función de costo E . Por otro lado una subpremisa que aparece inactiva para todos los pares puede ser eliminada junto con todas las reglas donde participa lo que también contribuye a la disminución de E . El criterio para el más alto número posible de funciones de pertenencia en siempre cero o de siempre uno, está dado por la siguiente ecuación con los números reales que actúan como factores de peso predefinidos ζ y η .

$$\text{OF}^{\text{UZ}} = \left(\frac{u_{\text{no}}}{(n+m)R_{\text{total}}} \right) \zeta + \left(\frac{z_{\text{no}}}{(n+m)R_{\text{total}}} \right) \eta + 1 \quad (1.45)$$

Donde u_{no} es el número de funciones que siempre tienen un valor de uno y z_{no} el número de las que siempre están en cero. Las funciones de pertenencia con valores de uno son reemplazadas por un trapecio que cubra todo el dominio, en cuanto que las cero, son cambiadas por funciones impulso.

Adicionalmente a los operadores genéticos comunes como cruce y mutación, se hace uso de dos nuevos operadores, ajustar a cero/uno el cual es utilizado para producir funciones de pertenencia que siempre tengan uno o cero, seleccionando al azar una función de pertenencia para una variable de entrada y salida y cambiando su sigma a un valor infinito ($+\infty$) en el caso de siempre

uno, o cero en el caso de una función de pertenencia de siempre cero. El otro operador genético empleado en la solución del problema es el llamado ajustar a similar, este operador selecciona aleatoriamente sobre cada variable de entrada/salida tomando una función de pertenencia y la hace igual a la función de pertenencia que más se le asemeje.

2. METODOLOGÍA DE SOLUCIÓN NUMÉRICA DEL PROBLEMA

En el proceso de simulación de la protección catódica de tuberías enterradas se pueden identificar dos etapas principales en la solución numérica del modelo propuesto:

1. Predicción de la Curva de Polarización del suelo
2. Optimización de las posiciones y corrientes de los electrodos para lograr la condición de protección.

Para llegar a cabo la primera etapa es necesario contar con un conjunto de suelos cuyos parámetros fisicoquímicos y curva de polarización del acero enterrado en el sean conocidos, sobre estos datos se debe realizar las siguientes actividades

- Dividir los datos disponibles de los suelos caracterizados en dos grupos, uno de ellos servirán para el proceso de entrenamiento y el otro para el de validación.
- Obtener las constantes de la curva de polarización, ecuación (1.7), a partir de los datos experimentales de pruebas potencioestáticas realizadas en los suelos de entrenamiento.
- Agrupar los suelos de entrenamiento según su corrosividad utilizando Agrupamiento borroso.

- Obtener automáticamente las reglas borrosas, para cada cluster de suelos, que predigan las constantes de la curva de polarización a partir de los parámetros fisicoquímicos de los suelos de entrenamiento.
- Validar el algoritmo con los datos de validación.

La finalidad de la primera parte de la simulación es que, a partir de un suelo problema, sea posible predecir la curva de polarización que se produce en un acero enterrado en él. Esta curva de polarización parametrizada servirá como condición de frontera en la solución de la ecuación de Laplace por elementos de contorno.

La segunda etapa de la simulación consiste en la optimización de las posiciones y corrientes de los electrodos para lograr la condición de protección, esta fase está controlada por un algoritmo genético constituido así:

- La función de adaptación calcula la distribución del potencial sobre la superficie de la tubería resolviendo numéricamente la ecuación de Laplace sometida a las siguientes condiciones de frontera:
 - Corriente conocida sobre los electrodos de corriente impresa cuyas posiciones son también conocidas. $J = J_e$
 - Densidad de corriente cero en la interfase suelo – aire. Ecuación (1.6)
 - Densidad de corriente como una función del potencial (curva de polarización) sobre la superficie de la estructura. Ecuación (1.7)
 - Continuidad de la corriente sobre la superficie de la estructura. Ecuación (1.13)

La ecuación diferencial parcial (1.5) es resuelta utilizando el método de los elementos de contorno. La función de adaptación calcula la potencia consumida por la configuración utilizando la ecuación (1.15) que finalmente es el objetivo de la optimización.

- Cada individuo de la población representa la codificación de las posiciones y corrientes de los electrodos de corriente impresa.

El algoritmo genético optimiza la posición y corriente de los electrodos para producir el mínimo consumo de potencia bajo condición protectora.

2.1 Predicción de la curva de polarización de un metal enterrado

Para simular la protección catódica es necesario contar con la información acerca del estado de polarización del metal. Esta tarea propia de la inteligencia artificial requiere una categorización previa del suelo según la corrosividad del mismo.

2.1.1 Agrupamiento de los suelos

Se debe partir de un conjunto de suelos arcillosos cuyas características principales sean conocidas: Resistividad, pH, contenidos de agua, cloruros, sulfatos, carbonatos, y corrosividad. Adicionalmente es imprescindible contar con una curva de polarización experimental, de la cual se deben extraer las constantes de la ecuación (1.7). Estos suelos caracterizados se dividirán en dos grupos, el primero de ellos se utilizará en el proceso de entrenamiento y el segundo para la validación de los resultados.

El algoritmo propuesto se describe a continuación.

//Agrupamiento de los suelos en tres clusters: Corrosividad alta, media y baja

1. Inicio
2. Extraer las constantes de la ecuación (1.7) utilizando algoritmos genéticos.
3. Normalizar el espacio espécimen. Ecuaciones (1.15), (1.16) y (1.17) obteniéndose un nuevo espacio espécimen normalizado.

$X = (x_{ij})$ que representa el parámetro j para el punto o suelo i .

4. Categorizar los suelos según su corrosividad en tres grupos: Alta, media y baja.
5. Dividir los datos en dos unas para el entrenamiento y otro para validación.

// Con los datos de entrenamiento///

6. Calcule la matriz de similaridad utilizando como función de similaridad:

$$d_{pq} = \begin{cases} 1 & \text{Cuando } p = q \\ 1 - 0,5 \sum_{k=1}^m |x_{ik} - x_{jk}| & \end{cases} \quad (2.1)$$

7. Calcular K según la ecuación (1.31)
8. Calcular R^{2K} que es el mismo R^* utilizando la ecuación (1.27)
9. Hacer Para cada grupo $i =$ (alto, medio y bajo)
10. Agrupados = falso
11. $\lambda_i = 1$
13. Hacer Mientras Agrupados = falso
14. $\lambda_i = \lambda_i - 0.1$
- 1.5 Si todos los suelos i fueron agrupados correctamente

Entonces

Agrupados = verdadero

Si no

Si $\lambda_i = 0$ Entonces

Error: Imposible agrupar i

Salir

16. Si no

17. imprimir: numero de suelos agrupados

correctamente

18. Fin Si

19. Fin Si

20. Fin Mientras

21. Fin Para

22. Fin

2.1.2 Generación de Reglas Base de Lógica Difusa

El objetivo de esta sección del algoritmo es crear un sistema basado en reglas borrosas para cada grupo de suelos y constante de la curva de polarización. Es decir, para cada grupo de suelo (corrosividad alta, media y baja) se crea un conjunto de reglas borrosas que permitan predecir el valor de cada constante de la ecuación (1.7).

El problema se resuelve utilizando algoritmos genéticos, cada individuo dentro de la población representa una posible solución que consta de los σ de las funciones de pertenencia, por otra parte en cada generación se determinará cuales reglas no fueron activadas y son cuales inocuas para ser eliminadas del sistema. Al finalizar quedarán el número de reglas mínimo con las funciones de pertenencia óptimas.

El algoritmo representado a continuación utiliza dos operadores genéticos adicionales a los tradicionales según se describió en la sección (1.4.3).

// Generación de reglas partiendo de los suelos categorizados:

1. Inicio
2. Hacer Para cada grupo de suelos $i =$ (alto, medio y bajo)
3. Determinar las funciones de pertenencia que representen el universo de cada parámetro
4. Hacer Para cada constante de la ecuación (1.7)
 $j = (U_1, U_2, U_3, b_1, b_2, b_3 \text{ e } i_L)$
5. Determinar las funciones de pertenencia que representen el universo de la constante

6. generación = 0, $OP = 1 \times 10^4$
7. Inicializar normalmente los valores de σ de las funciones de pertenencia
para crear una población inicial.
7. Hacer Mientras generación < max_generación o $OP \leq$ Tolerancia
8. generación = generación + 1
9. Hacer Para cada individuo
10. $OP = \max(\text{Ecuación (1.40) teniendo en cuenta (1.41)}$
a (1.46))
11. Fin Para
12. Seleccionar individuos
13. Cruzar
14. Mutar
15. Ajustar uno/cero
16. Ajustar a similar
17. Eliminar reglas en uno/cero
18. Eliminar reglas no activas
19. Fin Mientras
20. Fin Para
21. La solución para cada constante será el sistema con menor OP
22. Fin Para
23. La solución para cada grupo de suelo será el conjunto de sistemas solución
para cada constante
24. Fin

Los resultados del sistema basado en reglas borrosas obtenido mediante el anterior algoritmo debe ser validado utilizando los datos de validación. Si los resultados son satisfactorios, es posible predecir la curva de polarización de un suelo del cual se conozcan los parámetros fisicoquímicos utilizados para crear el modelo.

2.2 Optimización de la Protección Catódica

La optimización de la protección catódica de tuberías enterradas a las cuales se conoce su curva de polarización consta de dos secciones o módulos: solucionador de la ecuación de Laplace por el método de los elementos de contorno y optimización por medio de algoritmos genéticos.

2.2.1 Método Efectivo de Elementos de Contorno

Para minimizar el tiempo computacional de optimización los electrodos de corriente impresa son representados como puntos, de esta manera pueden ser movidos sin tener que recalcular las matrices H y G de la ecuación (1.10) puesto que la formulación de las variables es independiente del enmallado de los elementos de contorno. Para alcanzar este objetivo el modelo matemático debe ser reescrito como una ecuación de Poisson:

$$k\nabla^2 U(\chi) + b(\chi) = 0 \quad (2.2)$$

Donde es una función conocida.

En este caso, la representación integral de contorno (1.9) toma la forma:

$$C(P)U(P) + \int_{\Gamma} U(\chi)J^*(P, \chi)d\Gamma - \int_{\Gamma} U^*(P, \chi)J(\chi)d\Gamma + \int_{\Gamma} b(\chi)U^*(P, \chi)d\Gamma \quad (2.3)$$

Discretizando la ecuación (2.3) y aplicando la técnica de colocación, el nuevo sistema de ecuaciones toma la siguiente forma:

$$HU=GJ+B \quad (2.4)$$

La última integral de la ecuación (2.4) involucra sólo funciones conocidas y puede ser calculada analíticamente.

$$B(P) = \int_{\Gamma} b(\chi) U^*(P, \chi) d\Gamma \quad (2.5)$$

Considerando a los ánodos como puntos fuentes, el término $b(\chi)$ es igual a:

$$b(\chi) = b'(\chi', \chi) = P(\chi') \Delta(\chi', \chi) \quad (2.6)$$

Donde $P(\chi')$ es la densidad el punto fuente, $\Delta(\chi', \chi)$ es la función delta Dirac, y χ' es el punto fuente, por tanto:

$$B(P) = \int_{\Gamma} P(\chi') \Delta(\chi', \chi) U^*(P, \chi) d\Gamma = P(\chi') U^*(P, \chi') \quad (2.7)$$

El algoritmo de solución de los elementos de contorno consta de dos partes: una calcula las matrices de los coeficientes de influencia H y G; y la segunda que utilizando las condiciones de frontera, calcula la matriz B, impone la condición (1.13), y soluciona el sistema de ecuaciones no lineales resultante por un método de relajación.

Se considera que se conocen la geometría del problema, la curva de polarización del metal, y las posiciones y corrientes de los electrodos de corriente impresa.

2.2.1.1 Solución Numérica por Elementos Constantes

Si se discretiza la frontera en N_e elementos y se asume que la densidad de corriente y el potencial no varían en esos elementos, la ecuación integral de contorno efectiva (2.3) puede ser re escrita.

$$C(P)U(P) = \sum_{j=1}^{N_e} U_j \int_{\Gamma} J^*(P, \chi) d\Gamma - \sum_{j=1}^{N_e} J_j \int_{\Gamma} U^*(P, \chi) d\Gamma + \sum_{k=1}^{M_e} P(\chi'_k) U^*(P, \chi'_k) \quad (2.8)$$

Donde M_e es el número de electrodos de corriente impresa, y $P(\chi'_k)$ es la densidad de corriente del electrodo k.

Llamando

$$G_{ij} = \int_{\Gamma_j} U^*(P, \chi) d\Gamma_j \quad (2.9)$$

y

$$\hat{H}_{ij} = \int_{\Gamma_j} U^*(P, \chi) d\Gamma_j \quad H_{ij} = \hat{H}_{ij} + C_i \delta_{ij} \quad (2.10)$$

Con δ_{ij} el delta de Kronecker, la ecuación (2.8) puede ser rescrita en la forma.

$$\sum_{j=1}^{N_e} H_{ij} U_j = \sum_{j=1}^{N_e} G_{ij} J_j + B \quad (2.11)$$

Para cada punto nodal i, si se utiliza la ecuación anterior utilizando un técnica de colocación, para todos los puntos nodales a lo largo de una frontera, esto genera un sistema de ecuaciones que puede ser escrito en forma matricial.

El sistema resultante es no lineal, teniendo en cuenta la condición de frontera no lineal dada por la curva de polarización $J_i = f(U_i)$, y por tanto debe ser resuelto por un algoritmos tipo Newton – Raspón o algún otro, adicionalmente será necesario tener en cuenta la condición de continuidad de la corriente dada por la ecuación (1.13).

El sistema de ecuaciones no lineales resultante para dominios infinitos se muestra a continuación.

$$\begin{bmatrix} H_{11} & H_{12} & \cdots & H_{1N_e} & -1 \\ H_{21} & H_{22} & \cdots & H_{2N_e} & -1 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ H_{N_e 1} & H_{N_e 2} & \cdots & H_{N_e N_e} & -1 \\ 0 & 0 & \cdots & 0 & 0 \end{bmatrix} \begin{Bmatrix} U_1 \\ U_2 \\ \vdots \\ U_{N_e} \\ U_\infty \end{Bmatrix} - \begin{bmatrix} G_{11} & G_{12} & \cdots & G_{1N_e} \\ G_{21} & G_{22} & \cdots & G_{2N_e} \\ \vdots & \vdots & \ddots & \vdots \\ G_{N_e 1} & G_{N_e 2} & \cdots & G_{N_e N_e} \\ l_1 & l_2 & \cdots & l_{N_e} \end{bmatrix} \begin{Bmatrix} f(U_1) \\ f(U_2) \\ \vdots \\ f(U_{N_e}) \end{Bmatrix} = \begin{Bmatrix} B_1 \\ B_2 \\ \vdots \\ B_{N_e} \\ 0 \end{Bmatrix} \quad (2.12)$$

Sea la solución fundamental $U^* = \frac{1}{2\pi} \ln\left(\frac{1}{r}\right)$ con r la distancia entre P y χ , y

$$C(P) = \frac{1}{2}$$

//Cálculo de matrices de constantes de influencia

1. Inicio
2. Se discretiza la ecuación integral de contorno en N_e elementos
3. Hacer Para $i=1$ hasta N_e
4. Hacer Para $j=1$ hasta N_e
5. Si $i \neq j$ Entonces
6. Calcular $G(i,j)$ de la ecuación (2.9) utilizando cuadratura Gaussiana
7. Calcular $H(i,j)$ de la primer parte de la ecuación (2.10) utilizando cuadratura Gaussiana
8. Si No
9. Calcular $G(i,i)$ utilizando la ecuación

$$10. \quad G(i,i) = \frac{1}{\pi} |r| \left(\ln \frac{1}{|r|} + 1 \right) \quad (2.13)$$

11. Calcular $H(i,i)$ de la segunda parte de la ecuación (2.10)
12. Fin si
13. Fin Para
14. Fin Para
15. Hacer Para $i=1$ hasta N_e
16. $H(N_e+1,i)=0$

$$17. \quad G(N_e+1,i) = \Gamma_i$$

18. Fin Para

19. Fin

2.2.2 Optimización de Protección Catódica por Algoritmos Genéticos

La solución del problema inverso de protección catódica por medio de algoritmos genéticos requiere que las matrices de los coeficientes de influencia H y G sean conocidos, de manera que se utilice la formulación efectiva y ahorrar considerable tiempo de cálculo. Cada individuo en la población representa todas las posiciones y corrientes de los electrodos. La medida de la adaptación de los individuos incluye el consumo de potencia que la solución requiera y una función de penalización que sanciona fuertemente a los individuos que produzcan un potencial de no protección sobre algún punto de la estructura.

//Optimización de la Protección Catódica, se conocen de antemano las matrices H y G

1. Inicializar una población normal
2. generación = 0, convergencia = 1×10^4
3. Hacer Mientras generación < max_generación o convergencia <= Tolerancia
4. generación = generación + 1
5. Calcular la Matriz B según la ecuación (2.6)
6. Resolver el sistema de ecuaciones no lineales por método de relajación
7. Evaluar la aptitud de los individuos haciendo uso de la ecuación

$$8. \quad P^* = \sum_{e=1}^{N_A} U_e J_e + 1 \times 10^4 \sum_{k=1}^N [(-U_k - E_p)u(-U_k - E_p)]^2$$

(2.14)

Donde el subíndice e hace referencia al electrodo de corriente impresa

y u es la función de paso unitario

8. Seleccionar los individuos
9. Cruzar
10. Mutar
11. convergencia = $\max(P^*)$
12. Fin Mientras
13. La solución será el individuo mejor adaptado cuyo P^* sea el menor
14. Fin

3. ANALISIS DE RESULTADOS

3.1 Predicción de la curva de polarización del acero AISI 1020 enterrado en un suelo arcilloso

Como se mencionó en 2.1 para predecir la curva de polarización del metal enterrado en el suelo a partir de las características de este último, el primer paso es la categorización de los suelos en tres grupos según su corrosividad. Para esta tarea se empleó el método del agrupamiento borroso; posterior a esta actividad se generaron tres conjuntos de reglas difusas que correlacionaban mediante un sistema basado en reglas borrosas las constantes de la curva de polarización con los valores de las características del suelo.

3.1.1 Agrupamiento de los suelos

Se trabajó con los datos tomados en el área de Huandong en China, del estudio llevado a cabo a lo largo de las tuberías de Pulin y Changlin [16]. En la investigación mencionada se controlaron sistemáticamente sesenta y dos puntos, en estos puntos se tomaron las medidas de: la resistividad, el pH, el porcentaje de agua; la concentración de cloruros, sulfatos y carbonatos; y la corrosividad. Adicionalmente mediante una prueba potencioestática se registró una curva de polarización experimental. La tabla 3.1 muestra los datos normalizados de los suelos utilizados durante el proceso de entrenamiento

Los datos se dividieron en dos grupos, el primero de ellos se utilizó durante el proceso de entrenamiento, los datos restantes se utilizaron para la validación del modelo.

Tabla 3.1 Parámetros de suelo normalizados utilizados durante el proceso de entrenamiento

Suelo	R_norm	H2O_norm	pH_norm	Cl_norm	SO4_norm	CaCO3_norm	Agresividad Objetivo
8	-0,35	-1,99	1,15	1,37	-0,43	-0,02	MEDIA
12	1,14	0,09	0,66	-1,04	0,39	-0,18	MEDIA
13	1,19	0,16	0,67	1,10	-0,70	-0,38	MEDIA
16	-1,51	0,82	-1,21	0,04	-0,54	2,20	MEDIA
23	0,55	0,58	-0,28	-0,81	-1,08	-0,52	MEDIA
31	-0,69	-0,52	-1,43	-1,03	0,49	-0,77	MEDIA
37	-0,32	0,86	0,45	0,37	1,86	-0,34	MEDIA
33	-1,37	0,49	0,65	-0,55	-0,84	0,10	BAJA
34	-1,66	0,45	-0,90	0,95	0,03	-0,58	BAJA
38	-0,70	0,40	0,09	0,15	-1,68	0,48	BAJA
39	1,12	0,47	-1,53	-0,58	-0,69	0,44	BAJA
41	-0,05	0,48	0,93	-0,32	-0,08	0,14	BAJA
43	-0,53	0,55	-0,88	0,54	-0,42	-0,46	BAJA
44	0,89	-0,96	-0,46	-1,08	0,04	2,44	BAJA
48	0,98	0,28	0,15	2,30	1,49	-0,56	BAJA
49	0,26	0,26	0,48	-0,06	-0,46	-1,41	BAJA
54	1,23	0,31	-0,55	-1,25	1,19	-0,82	BAJA
58	-0,17	-2,73	2,00	-0,10	1,41	0,25	BAJA
28	-0,29	-0,65	-0,73	1,00	-0,46	0,31	ALTA
30	-0,21	-0,60	-1,08	-1,12	-0,25	0,31	ALTA
32	0,70	-0,59	-1,48	1,79	0,93	0,98	ALTA
35	-0,76	1,00	0,16	-0,22	-0,94	-0,28	ALTA
36	-1,98	0,91	0,10	-1,00	-0,60	-0,35	ALTA
42	1,30	0,83	-0,43	-1,14	-1,05	0,63	ALTA
45	1,12	-0,47	-0,86	0,17	0,68	2,36	ALTA
50	-0,27	0,77	-0,31	-0,65	1,45	-1,47	ALTA
51	-1,21	0,87	1,20	0,15	1,60	-0,50	ALTA
52	1,10	0,75	1,36	-0,72	0,47	-1,31	ALTA
57	-0,24	-2,48	1,94	1,17	-1,20	-0,75	ALTA
60	1,01	-0,19	0,13	-0,63	-1,19	-0,05	ALTA
61	-0,28	-0,16	0,00	1,20	0,57	0,12	ALTA

Haciendo uso de la ecuación (1.30) se calculó K

$$K - 1 < \log_2 31 \leq K \qquad K - 1 < 4.959 \leq K \qquad K=5$$

Por tanto el algoritmo multiplica borrosamente la matriz de similaridad 4 veces por ella misma para así obtener la matriz de equivalencia.

$$R \rightarrow R^2 \rightarrow R^4 \rightarrow R^8 \rightarrow R^{16} = R^*$$

3.1.1.1 Selección del corte

Mediante ensayo y error se determinaron los valores de corte λ , seleccionando valores progresivamente inferiores hasta que los suelos fueran agrupados correctamente.

Para valores de corte altos el grupo de los suelos de corrosividad media mostró fuerte tendencia al agrupamiento hasta al alcanzar su máximo en $\lambda = 0.6$, cuando todos los individuos fueron agrupados correctamente, al exceder este valor se observa un sobre agrupamiento, es decir que especímenes pertenecientes a otros grupos se declaran como de corrosividad media; por esta razón se escogió 0.6 como el corte medio $\lambda_m = 0.6$.

En la figura 3.1 se detallan la cantidad de suelos agrupados para cortes de 1 a 0.6.

Al seguir disminuyendo los valores de corte se encontró que para λ entre 0.6 y 0.3 los individuos catalogados como suelos de baja corrosividad tienden a formar un grupo, siendo agrupados correctamente todos los individuos al valor de corte $\lambda_B = 0.3$, sin que se manifieste presencia de otros especímenes de corrosividad diferente a la baja dentro del cluster. En la figura 3.2 se puede visualizar el proceso de selección del corte respectivo.

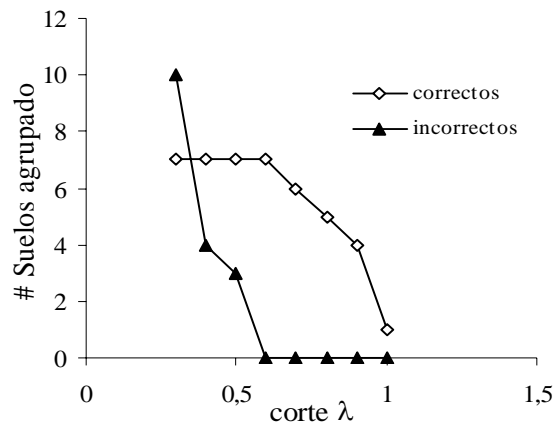


Figura 3.1 Número de suelos de corrosividad media agrupados Vs corte .

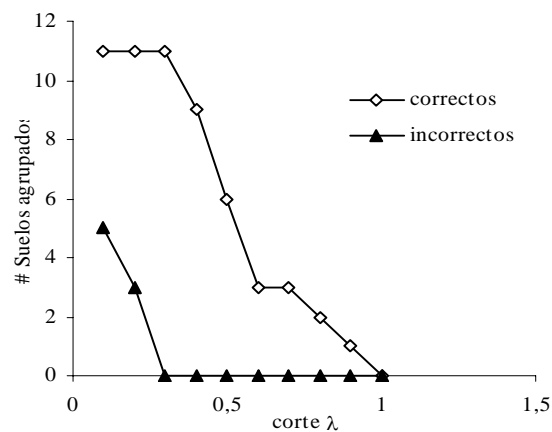


Figura 3.2 Número de suelos de corrosividad baja agrupados Vs corte .

Continuando con el procedimiento descrito en el algoritmo de la sección 2.1.1 se encontró que para λ entre 0.3 y 0.0 los individuos catalogados como suelos de baja corrosividad tienden a formar un grupo, siendo agrupados correctamente todos los individuos al valor de corte $\lambda_B = 0.0$, puesto que los otros especímenes con corrosividad diferente, ya formaban parte de clusters diferentes. En la figura 3.2 se puede visualizar el proceso de selección del corte respectivo.

Los valores de los corte fueron validados utilizando para ello los datos de los suelos que no formaron parte del proceso de entrenamiento.

La validación mostró que los valores de corte seleccionados eran también los adecuados para los datos de los otros suelos, sólo en el caso del suelo del espécimen número 6 que fue agrupado en el conjunto de los suelos de corrosividad media, cuando se esperaba que lo fuera en el de corrosividad alta. Sin embargo se puede decir que el proceso fue satisfactorio para el 98.4% de los datos ensayados.

3.1.2 Obtención del sistema basado en reglas borrosas

Con los resultados de la sección anterior se procedió a crear un sistema de inferencia basado en reglas borrosas para cada uno de los grupos de suelos.

Cada sistema actúa sobre seis variables de entrada: R, pH, %H₂O, [Cl⁻],[SO₄⁻], y %CaCO₃; para obtener siete variables respuesta: U1, U2, U3, B1, B2, B3, e IL las cuales conforman la curva de polarización.

$$J = e^{(U-U_1)/B_1} - \left(\frac{1}{IL} + \frac{1}{e^{(U-U_2)/B_2}} \right)^{-1} - e^{-(U-U_3)/B_3} \quad (3.1)$$

Siendo:

Los conjuntos de entrada:

$$X = \{R, \text{ pH, \%H}_2\text{O, [Cl]^{-}, [SO}_4\text{]^{-}, \%CaCO}_3\}$$

Los conjuntos de Salida:

$$O = \{U_1, U_2, U_3, B_1, B_2, B_3, IL\}$$

Con los rótulos lingüísticos:

$$L = \{\text{Alto, Medio, Bajo}\}$$

El sistema de reglas iniciales para el todos los grupos fue configurado de acuerdo con:

Re gla_k : Si X es L Entonces O_i es L

Donde k = 1,2, ...,343 e i = 1,2,...,7

Por simplicidad de la función de adaptación se escogieron los factores de peso a, b, γ , ζ y η iguales a 0.5. Ecuaciones (1.43), (1.44), y (1.45)

Todas los sistemas basados en reglas borrosas fueron obtenidos de forma automática, mediante el procedimiento de a aprendizaje descrito en la sección 2.1.2.

3.1.2.1 Grupo de suelos de baja corrosividad

Al algoritmo genético que potencia la optimización del sistema se ajustaron los parámetros iniciales como se aprecia en la tabla 3.2.

Tabla 3.2 Parámetros iniciales del algoritmo genético que optimiza al sistema basado en reglas para predecir las constantes U1, U2, U3, B1, B2, B3 y IL en el grupo de suelos de baja corrosividad.

Parámetro	Valor
Número de generaciones máximo	1400
Población inicial	15
Probabilidad de cruce	0.01
Probabilidad de mutación	0.5
Probabilidad de ajuste uno/cero	0.01
Umbral de semejanza	0.001

3.1.2.1.1 Generación del sistema para U1

La aplicación del algoritmo arrojó como resultado el ajuste de las funciones de pertenencia modificando el conjunto L. Adicionalmente redujo el número de reglas a 10.

Las funciones de pertenencia triangulares finales se pueden apreciar en la tabla 3.3

Tabla 3.3 Funciones de pertenencia después del proceso de entrenamiento de los suelos de baja corrosividad en la predicción del parámetro U1

	BAJO	MEDIO	ALTO
Resistividad	25 – 27.5	26.9 – 28.8	28.1 – 32
Humedad	8 – 15.3	10.6 – 30.4	25.7 – 37
Ph	5 – 7.8	6.8 – 10.4	9.2 – 12
Cloruros	0.2 – 0.59	0.45 – 0.81	0.76 – 0.99
Sulfatos	0.0 – 1.1	0.7 – 1.8	1.4 – 2.2
Carbonato de Calcio	4.0 – 6.1	5.3 – 8.7	7.5 – 11.0

En la tabla 3.4 se describen las reglas generadas por el algoritmo. Las reglas resultantes son muy parecidas a las que se podrían inferir *a priori* con respecto al parámetro U1 que representa el potencial del Hierro y su corrimiento de acuerdo a las condiciones del suelo, por ejemplo a condiciones más agresivas tales como baja resistividad, alta concentración de iones cloruro, bajo pH, bajo contenido de CaCO₃, alto contenido de iones sulfato, el potencial del hierro tiene a tomar valores más altos.

Tabla 3.4 Sistema base de reglas borrosas para la predicción de U1 en suelos de corrosividad baja

		Premisas											Consecuencia		
		Is	And	Is	And	Is	And	Is	And	Is	And	Is			ES
IF	R	B	H ₂ O	A	pH	B	Cl	A	SO ₄	A	CaCO ₃	B	THEN	U1	A

IF	R	B	H ₂ O	A	pH	B	Cl	A	SO ₄	M	CaCO ₃	B	THEN	U1	A
IF	R	B	H ₂ O	A	pH	M	Cl	B	SO ₄	M	CaCO ₃	B	THEN	U1	A
IF	R	M	H ₂ O	M	pH	M	Cl	M	SO ₄	A	CaCO ₃	A	THEN	U1	M
IF	R	M	H ₂ O	M	pH	M	Cl	M	SO ₄	B	CaCO ₃	M	THEN	U1	M
IF	R	A	H ₂ O	B	pH	A	Cl	B	SO ₄	B	CaCO ₃	A	THEN	U1	B
IF	R	A	H ₂ O	B	pH	A	Cl	B	SO ₄	M	CaCO ₃	M	THEN	U1	B
IF	R	A	H ₂ O	B	pH	A	Cl	B	SO ₄	A	CaCO ₃	B	THEN	U1	B
IF	R	M	H ₂ O	A	pH	M	Cl	B	SO ₄	M	CaCO ₃	A	THEN	U1	M
IF	R	M	H ₂ O	A	pH	B	Cl	B	SO ₄	A	CaCO ₃	B	THEN	U1	B

La evolución del algoritmo genético se puede apreciar en la figura 3.3, el ajuste del algoritmo a los valores de salida de U1 se detalla en la figura 3.4.

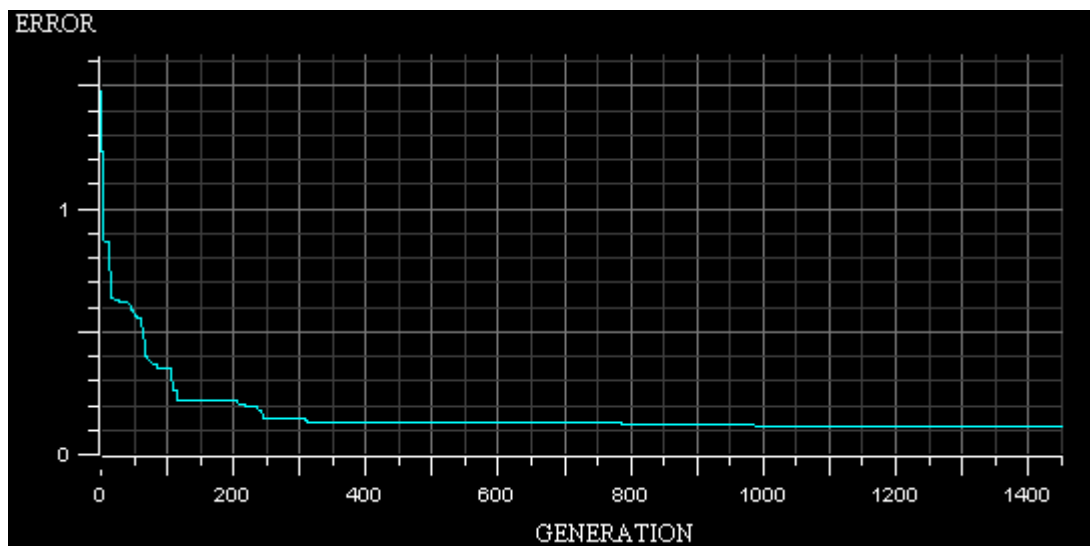


Figura 3.3 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de U1 en suelos de baja corrosividad.

Se alcanzó una correlación de 0.919593 con los datos de entrenamiento y de 0.9002 con los de validación, esta diferencia es normal problemas de aprendizaje autónomo y se considera satisfactoria.

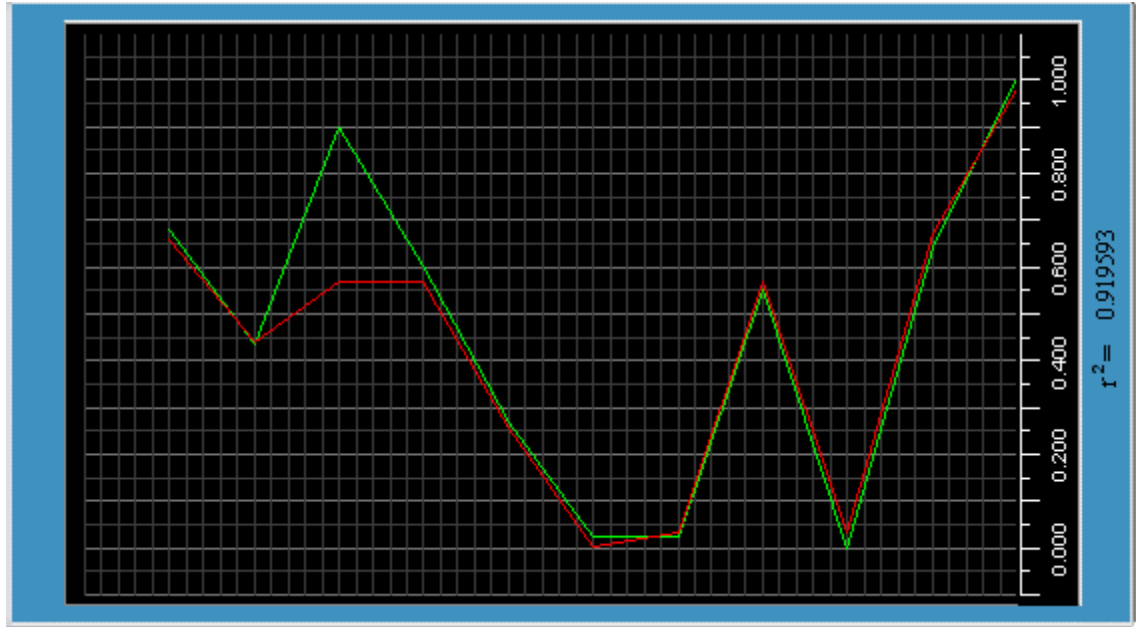


Figura 3.4 Ajuste del algoritmo a los valores de salida de U1 durante la fase de entrenamiento del sistema basado en reglas para suelos de baja corrosividad

3.1.2.1.2 Generación del sistema para U2

En el proceso de entrenamiento se obtuvieron tanto el ajuste de las funciones de pertenencia como la reducción del número de reglas de 343 a 8.

Las funciones de pertenencia triangulares finales se pueden apreciar en la tabla 3.5. no se observan cambios radicales en los rangos de las funciones triangulares, excepto en el caso del pH; este resultado puede atribuirse al hecho de que U2 representa el potencial del Oxígeno, el cual es sensible a este factor.

Tabla 3.5 Funciones de pertenencia después del proceso de entrenamiento de los suelos de baja corrosividad en la predicción del parámetro U2.

	BAJO	MEDIO	ALTO
Resistividad	25 – 28.1	26.5 – 29.1	28.6 – 32
Humedad	8 – 18.6	12.8 – 33.3	26.2 – 37
Ph	5 – 7.5	4.1 – 10.4	9.5 – 12
Cloruros	0.2 – 0.59	0.45 – 0.83	0.66 – 0.99

Sulfatos de Carbonato de Calcio	0.0 – 1.5	0.9 – 1.9	1.1 – 2.2
	4.0 – 6.3	5.4 – 8.9	7.5 – 11.0

En la tabla 3.6 pueden apreciar las reglas generadas por el algoritmo. Se observa nuevamente que al igual que en los rangos de las funciones de pertenencia, el pH toma mayor relevancia en el sistema de reglas borrosas.

Tabla 3.6 Sistema base de reglas borrosas para la predicción de U2 en suelos de corrosividad baja

		Premisas											Consecuencia		
		Is	And	Is	And	Is	And	Is	And	Is	And	Is			ES
IF	R	B	H ₂ O	A	pH	A	Cl	M	SO ₄	A	CaCO ₃	M	THEN	U2	A
IF	R	B	H ₂ O	A	pH	A	Cl	B	SO ₄	A	CaCO ₃	B	THEN	U2	A
IF	R	B	H ₂ O	A	pH	A	Cl	A	SO ₄	M	CaCO ₃	B	THEN	U2	A
IF	R	M	H ₂ O	B	pH	A	Cl	A	SO ₄	A	CaCO ₃	A	THEN	U2	A
IF	R	A	H ₂ O	M	pH	M	Cl	B	SO ₄	M	CaCO ₃	M	THEN	U2	M
IF	R	M	H ₂ O	B	pH	M	Cl	M	SO ₄	B	CaCO ₃	M	THEN	U2	M
IF	R	A	H ₂ O	A	pH	B	Cl	B	SO ₄	M	CaCO ₃	M	THEN	U2	B
IF	R	A	H ₂ O	B	pH	A	Cl	B	SO ₄	B	CaCO ₃	B	THEN	U2	M

La evolución del algoritmo genético se puede apreciar en la figura 3.5, el ajuste del algoritmo a los valores de salida de U2 se detalla en la figura 3.6.

3.1.2.1.3 Generación del sistema para U3

En el proceso de entrenamiento se obtuvieron tanto el ajuste de las funciones de pertenencia como la reducción del número de reglas de 343 a 14

Las funciones de pertenencia triangulares finales se pueden apreciar en la tabla 3.5. El proceso de entrenamiento arrojó como resultado una ampliación en el rango de acción del rótulo lingüístico BAJO para el pH y el ALTO para la

concentración de cloruros, esta variación en la representación resalta, por un lado, el efecto que un pH más ácido tiene sobre el potencial del hidrógeno, y en adición la mejora en el transporte de carga que implica una mayor concentración de iones cloruro.




Figura 3.5 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de U2 en suelos de baja corrosividad




Figura 3.6 Ajuste del algoritmo a los valores de salida de U2 durante la fase de entrenamiento del sistema basado en reglas para suelos de baja corrosividad

Tabla 3.7 Funciones de pertenencia después del proceso de entrenamiento de los suelos de baja corrosividad en la predicción del parámetro U3.

		BAJO	MEDIO	ALTO
Resistividad		25 – 28.2	26.7 – 29.4	28.2 – 32
Humedad		8 – 19.3	11.7 – 32.6	25.4 – 37
Ph		5 – 8.2	6.4 – 12.1	10.5 – 12
Cloruros		0.2 – 0.42	0.3 – 0.66	0.4 – 0.99
Sulfatos		0.0 – 1.5	0.7 – 1.7	1.3 – 2.2
Carbonato de Calcio		4 – 6.5	5.1 – 8.8	7.7 – 11

Tabla 3.8 Sistema base de reglas borrosas para la predicción de U3 en suelos de corrosividad baja

	Premisas												Consecuencia		
		Is	And	Is	And	Is	And	Is	And	Is	And	Is			ES
IF	R	B	H ₂ O	A	pH	B	Cl	A	SO ₄	B	CaCO ₃	B	THEN	U3	A
IF	R	B	H ₂ O	A	pH	B	Cl	A	SO ₄	B	CaCO ₃	B	THEN	U3	A
IF	R	B	H ₂ O	M	pH	B	Cl	A	SO ₄	M	CaCO ₃	B	THEN	U3	A
IF	R	B	H ₂ O	B	pH	M	Cl	A	SO ₄	M	CaCO ₃	A	THEN	U3	A
IF	R	A	H ₂ O	B	pH	A	Cl	M	SO ₄	B	CaCO ₃	M	THEN	U3	B
IF	R	M	H ₂ O	B	pH	A	Cl	M	SO ₄	B	CaCO ₃	B	THEN	U3	M
IF	R	A	H ₂ O	M	pH	M	Cl	B	SO ₄	A	CaCO ₃	M	THEN	U3	M
IF	R	A	H ₂ O	B	pH	A	Cl	B	SO ₄	B	CaCO ₃	B	THEN	U3	B
IF	R	B	H ₂ O	M	pH	A	Cl	A	SO ₄	M	CaCO ₃	A	THEN	U3	B
IF	R	M	H ₂ O	A	pH	M	Cl	A	SO ₄	M	CaCO ₃	B	THEN	U3	B
IF	R	B	H ₂ O	M	pH	A	Cl	B	SO ₄	A	CaCO ₃	M	THEN	U3	M
IF	R	B	H ₂ O	M	pH	B	Cl	M	SO ₄	B	CaCO ₃	B	THEN	U3	B

IF	R	B	H ₂ O	M	pH	A	Cl	M	SO ₄	M	CaCO ₃	A	THEN	U3	M
IF	R	B	H ₂ O	B	pH	M	Cl	A	SO ₄	M	CaCO ₃	B	THEN	U3	M

La evolución del algoritmo genético se puede apreciar en la figura 3.7, el ajuste del algoritmo a los valores de salida de U3 se detalla en la figura 3.8.

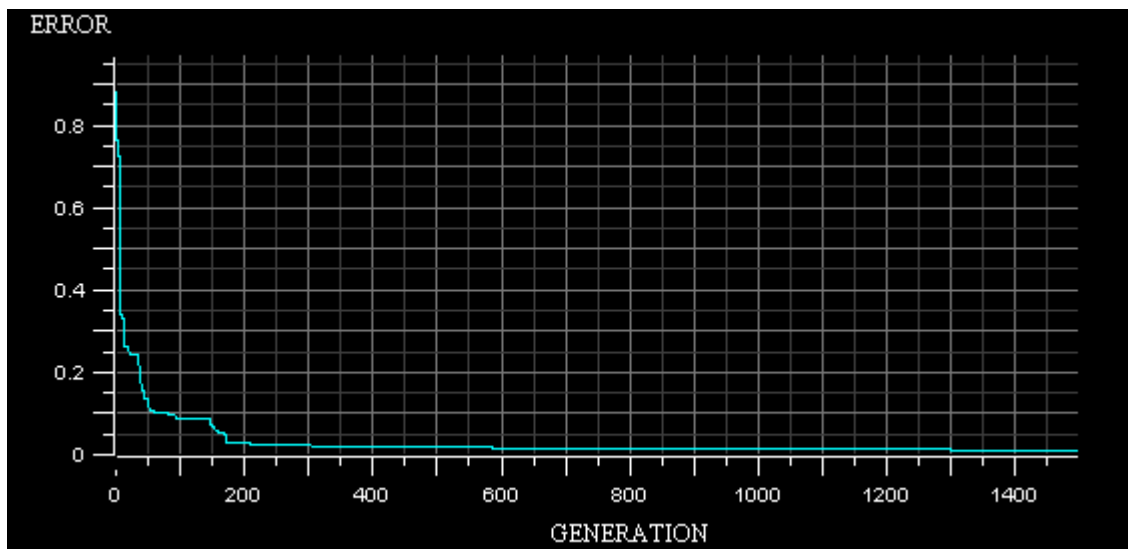


Figura 3.7 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de U3 en suelos de baja corrosividad.




Figura 3.8 Ajuste del algoritmo a los valores de salida de U3 durante la fase de entrenamiento del sistema basado en reglas para suelos de baja corrosividad

3.1.2.1.4 Predicción de B1

Se asumió que las constantes B tienen un comportamiento lógico similar a las U, por lo que se toman las mismas funciones de pertenencia y sólo se optimizan las reglas base

La aplicación del algoritmo arrojó como resultado la reducción del número de reglas a 7, tabla 3.9.

Tabla 3.9 Sistema base de reglas borrosas para la predicción de B1 en suelos de corrosividad baja

		Premisas											Consecuencia		
		Is	And	Is	And	Is	And	Is	And	Is	And	Is			ES
IF	R	M	H ₂ O	M	pH	B	Cl	M	SO ₄	B	CaCO ₃	M	THEN	B1	B
IF	R	B	H ₂ O	A	pH	A	Cl	A	SO ₄	M	CaCO ₃	B	THEN	B1	M
IF	R	B	H ₂ O	B	pH	B	Cl	B	SO ₄	A	CaCO ₃	A	THEN	B1	A
IF	R	M	H ₂ O	B	pH	M	Cl	A	SO ₄	B	CaCO ₃	B	THEN	B1	M
IF	R	M	H ₂ O	A	pH	M	Cl	B	SO ₄	M	CaCO ₃	A	THEN	B1	A
IF	R	M	H ₂ O	A	pH	A	Cl	M	SO ₄	A	CaCO ₃	M	THEN	B1	B
IF	R	A	H ₂ O	B	pH	M	Cl	B	SO ₄	A	CaCO ₃	M	THEN	B1	M

La evolución del algoritmo genético se puede apreciar en la figura 3.9, el ajuste del algoritmo a los valores de salida de B1 se detalla en la figura 3.10.

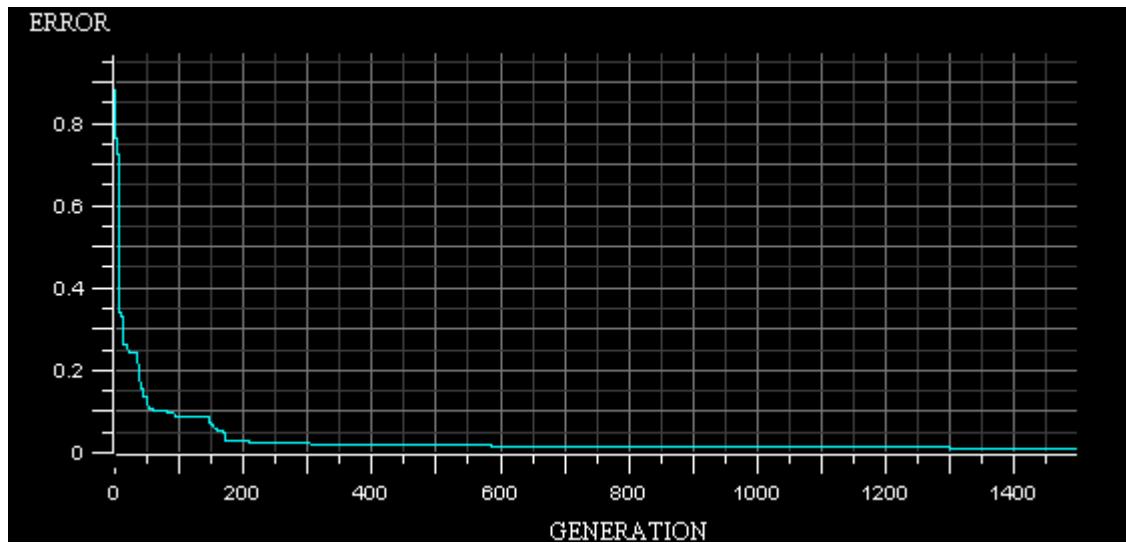


Figura 3.9 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de B1 en suelos de baja corrosividad.

La correlación alcanzada fue particularmente buena 0.992481, tal vez debido a la simplicidad del espacio objetivo, como se puede observar en la figura 3.10.

3.1.2.1.5 Predicción de B2

La aplicación del algoritmo arrojó como resultado la reducción del número de reglas a 6, tabla 3.10.

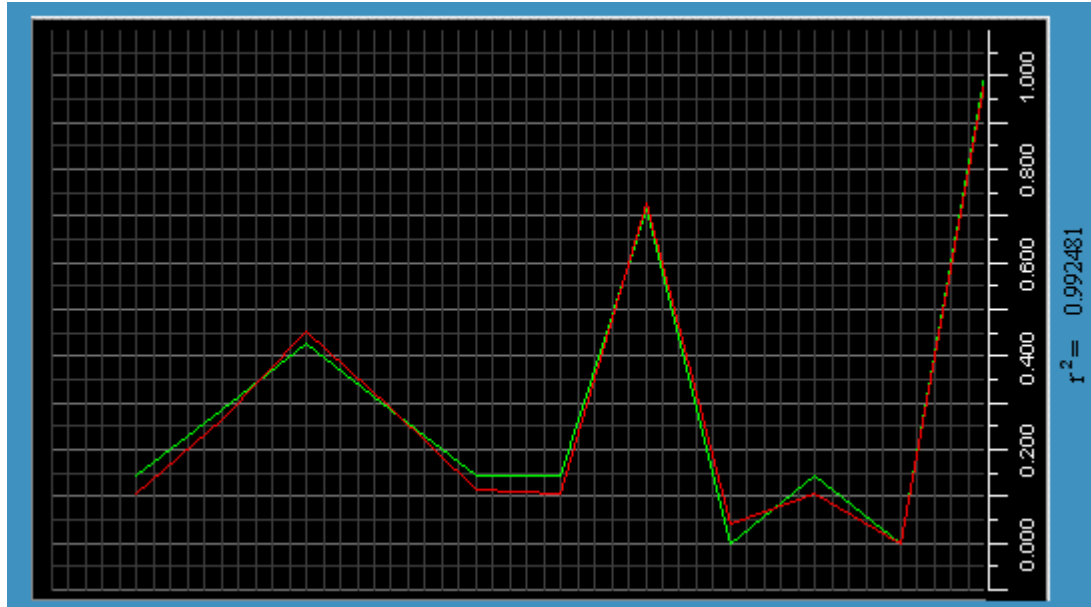


Figura 3.10 Ajuste del algoritmo a los valores de salida de B1 durante la fase de entrenamiento del sistema basado en reglas para suelos de baja corrosividad

Tabla 3.10 Sistema base de reglas borrosas para la predicción de B2 en suelos de corrosividad baja

	Premisas												Consecuencia		
		Is	And	Is	And	Is	And	Is	And	Is	And	Is			ES
IF	R	M	H ₂ O	M	pH	B	Cl	M	SO ₄	B	CaCO ₃	M	THEN	B2	B
IF	R	B	H ₂ O	A	pH	A	Cl	A	SO ₄	M	CaCO ₃	B	THEN	B2	M
IF	R	B	H ₂ O	B	pH	B	Cl	B	SO ₄	A	CaCO ₃	A	THEN	B2	A
IF	R	M	H ₂ O	B	pH	M	Cl	A	SO ₄	B	CaCO ₃	B	THEN	B2	M
IF	R	M	H ₂ O	A	pH	M	Cl	B	SO ₄	M	CaCO ₃	A	THEN	B2	A
IF	R	M	H ₂ O	A	pH	A	Cl	M	SO ₄	A	CaCO ₃	M	THEN	B2	B

La evolución del algoritmo genético se puede apreciar en la figura 3.11, el ajuste del algoritmo a los valores de salida de B2 se detalla en la figura 3.12.

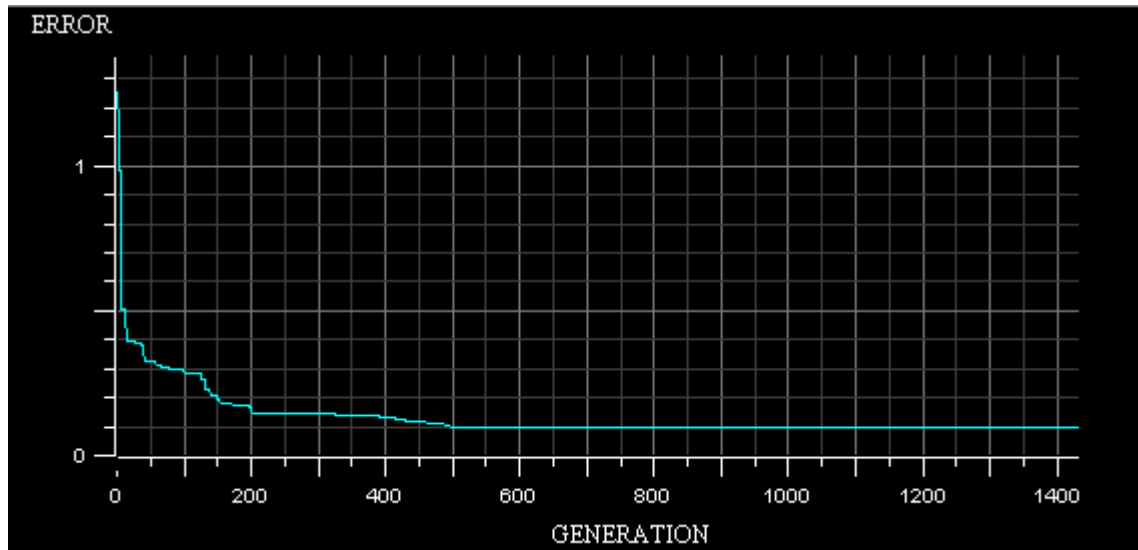


Figura 3.11 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de B2 en suelos de baja corrosividad.




Figura 3.12 Ajuste del algoritmo a los valores de salida de B2 durante la fase de entrenamiento del sistema basado en reglas para suelos de baja corrosividad

3.1.2.1.6 Predicción de B3

La aplicación del algoritmo arrojó como resultado la reducción del número de reglas a 8, tabla 3.11.

Tabla 3.11 Sistema base de reglas borrosas para la predicción de B3 en suelos de corrosividad baja

	Premisas												Consecuencia		
		Is	And	Is	And	Is	And	Is	And	Is	And	Is			ES
IF	R	B	H ₂ O	A	pH	B	Cl	M	SO ₄	B	CaCO ₃	A	THEN	B3	A
IF	R	B	H ₂ O	A	pH	A	Cl	A	SO ₄	B	CaCO ₃	M	THEN	B3	A
IF	R	B	H ₂ O	B	pH	M	Cl	B	SO ₄	A	CaCO ₃	A	THEN	B3	A
IF	R	M	H ₂ O	M	pH	M	Cl	A	SO ₄	M	CaCO ₃	B	THEN	B3	M
IF	R	A	H ₂ O	A	pH	B	Cl	B	SO ₄	M	CaCO ₃	B	THEN	B3	B
IF	R	A	H ₂ O	B	pH	A	Cl	M	SO ₄	A	CaCO ₃	A	THEN	B3	B
IF	R	M	H ₂ O	B	pH	M	Cl	M	SO ₄	A	CaCO ₃	A	THEN	B3	M
IF	R	B	H ₂ O	B	pH	A	Cl	B	SO ₄	M	CaCO ₃	A	THEN	B3	A

La evolución del algoritmo genético se puede apreciar en la figura 3.13, el ajuste del algoritmo a los valores de salida de B3 se detalla en la figura 3.14.

3.1.2.1.7 Predicción de IL

La aplicación del algoritmo arrojó como resultado la reducción del número de reglas a 5, tabla 3.12.

Tabla 3.12 Sistema base de reglas borrosas para la predicción de IL en suelos de corrosividad baja

	Premisas	Consecuencia
--	----------	--------------

		Is	And	Is	And	Is	And	Is	And	Is	And	Is			ES
IF	R	B	H ₂ O	A	pH	B	Cl	A	SO ₄	A	CaCO ₃	A	THEN	B3	B
IF	R	B	H ₂ O	A	pH	M	Cl	A	SO ₄	B	CaCO ₃	M	THEN	B3	B
IF	R	B	H ₂ O	B	pH	A	Cl	M	SO ₄	A	CaCO ₃	A	THEN	B3	M
IF	R	M	H ₂ O	M	pH	M	Cl	B	SO ₄	M	CaCO ₃	M	THEN	B3	M
IF	R	A	H ₂ O	A	pH	B	Cl	M	SO ₄	B	CaCO ₃	B	THEN	B3	A

La evolución del algoritmo genético se puede apreciar en la figura 3.15, el ajuste del algoritmo a los valores de salida de IL se detalla en la figura 3.16.

La información del sistema basado en reglas borrosas arrojó un ajuste que varía entre 0.92 y 0.99 a los datos experimentales tanto de entrenamiento como de validación, de los suelos de corrosividad baja, aún cuando los parámetros de los suelos varíen en órdenes de magnitud entre 2 y 5.




Figura 3.13 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de B3 en suelos de baja corrosividad.




Figura 3.14 Ajuste del algoritmo a los valores de salida de B3 durante la fase de entrenamiento del sistema basado en reglas para suelos de baja corrosividad




Figura 3.15 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de IL en suelos de baja corrosividad.

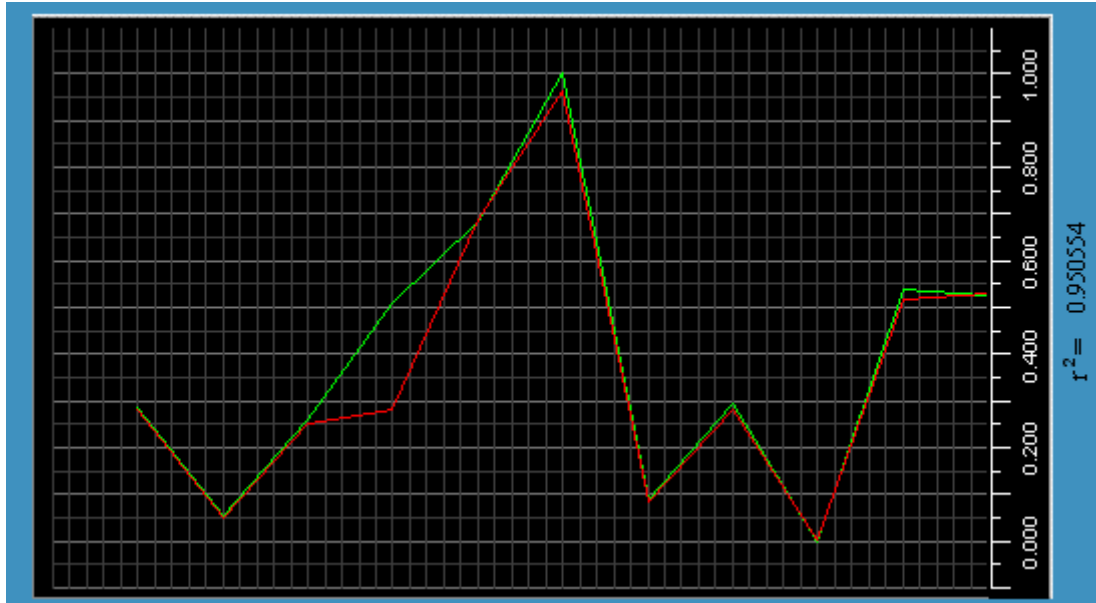


Figura 3.16 Ajuste del algoritmo a los valores de salida de IL durante la fase de entrenamiento del sistema basado en reglas para suelos de baja corrosividad

3.1.2.2 Grupo de suelos de corrosividad media

Al algoritmo genético que potencia la optimización del sistema se ajustaron los parámetros iniciales como se aprecia en la tabla 3.13.

Tabla 3.13 Parámetros iniciales del algoritmo genético que optimiza al sistema basado en reglas para predecir las constantes U1, U2, U3, B1, B2, B3 y IL en el grupo de suelos de corrosividad media.

Parámetro	Valor
Número de generaciones máximo	1400
Población inicial	15
Probabilidad de cruce	0.01
Probabilidad de mutación	0.5
Probabilidad de ajuste uno/cero	0.01
Umbral de semejanza	0.001

3.1.2.2.1 Generación del sistema para U1

La aplicación del algoritmo arrojó como resultado el ajuste de las funciones de pertenencia modificando el conjunto L. Adicionalmente redujo el número de reglas a 13.

Las funciones de pertenencia triangulares finales se pueden apreciar en la tabla 3.14

Tabla 3.14 Funciones de pertenencia después del proceso de entrenamiento de los suelos de corrosividad media en la predicción del parámetro U1.

		BAJO	MEDIO	ALTO
Resistividad		25 – 28.5	27.2 – 29.1	27.3 – 31
Humedad		10 – 17.3	12.2 – 29.4	24.6 – 36
Ph		6 – 8.7	6.9 – 9.8	8.2 – 11
Cloruros		0.1 – 0.68	0.45 – 0.94	0.71 – 1.3
Sulfatos		0.1 – 0.73	0.3 – 0.92	0.6 – 1.4
Carbonato de Calcio		5.0 – 6.3	5.2 – 8.8	7.5 – 11.0

En la tabla 3.15 se describen las reglas generadas por el algoritmo.

Tabla 3.15 Sistema base de reglas borrosas para la predicción de U1 en suelos de corrosividad media.

	Premisas												Consecuencia		
		Is	And	Is	And	Is	And	Is	And	Is	And	Is			ES
IF	R	B	H ₂ O	A	pH	B	Cl	A	SO ₄	A	CaCO ₃	B	THEN	U1	A
IF	R	B	H ₂ O	A	pH	B	Cl	A	SO ₄	M	CaCO ₃	M	THEN	U1	A
IF	R	M	H ₂ O	A	pH	M	Cl	B	SO ₄	B	CaCO ₃	B	THEN	U1	A
IF	R	M	H ₂ O	M	pH	M	Cl	M	SO ₄	M	CaCO ₃	A	THEN	U1	B
IF	R	M	H ₂ O	M	pH	A	Cl	M	SO ₄	B	CaCO ₃	M	THEN	U1	B
IF	R	A	H ₂ O	B	pH	A	Cl	B	SO ₄	B	CaCO ₃	B	THEN	U1	B
IF	R	A	H ₂ O	B	pH	A	Cl	B	SO ₄	M	CaCO ₃	M	THEN	U1	M

IF	R	A	H ₂ O	B	pH	A	Cl	B	SO ₄	A	CaCO ₃	B	THEN	U1	M
IF	R	M	H ₂ O	A	pH	M	Cl	B	SO ₄	M	CaCO ₃	A	THEN	U1	M
IF	R	M	H ₂ O	M	pH	B	Cl	B	SO ₄	A	CaCO ₃	A	THEN	U1	B
IF	R	A	H ₂ O	A	pH	A	Cl	B	SO ₄	A	CaCO ₃	B	THEN	U1	B
IF	R	A	H ₂ O	A	pH	M	Cl	M	SO ₄	M	CaCO ₃	A	THEN	U1	M
IF	R	A	H ₂ O	A	pH	B	Cl	B	SO ₄	A	CaCO ₃	B	THEN	U1	B

La evolución del algoritmo genético se puede apreciar en la figura 3.3, el ajuste del algoritmo a los valores de salida de U1 se detalla en la figura 3.17.

3.1.2.2 Generación del sistema para U2

En el proceso de entrenamiento se obtuvieron tanto el ajuste de las funciones de pertenencia como la reducción del número de reglas de 343 a 7.

Las funciones de pertenencia triangulares finales se pueden apreciar en la tabla 3.16; no se observan cambios radicales en los rangos de las funciones triangulares.




Figura 3.17 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de U1 en suelos de corrosividad media.




Figura 3.18 Ajuste del algoritmo a los valores de salida de U1 durante la fase de entrenamiento del sistema basado en reglas para suelos de corrosividad media

Tabla 3.16 Funciones de pertenencia después del proceso de entrenamiento de los suelos de corrosividad media en la predicción del parámetro U2.

	BAJO	MEDIO	ALTO
Resistividad	25 – 28.7	27.2 – 29.1	27.3 – 31
Humedad	10 – 17.3	12.2 – 29.4	24.6 – 36
Ph	6 – 8.5	6.8 – 9.7	8.8 – 11
Cloruros	0.1 – 0.71	0.45 – 0.94	0.74 – 1.3
Sulfatos	0.1 – 0.76	0.3 – 0.92	0.65 – 1.4
Carbonato de Calcio	5.0 – 7.3	5.5 – 8.9	7.2 – 11.0

En la tabla 3.17 pueden apreciar las reglas generadas por el algoritmo. Se observa nuevamente que al igual que en los rangos de las funciones de pertenencia, el pH toma mayor relevancia en el sistema de reglas borrosas.

Tabla 3.17 Sistema base de reglas borrosas para la predicción de U2 en suelos de corrosividad media

	Premisas												Consecuencia		
		Is	And	Is	And	Is	And	Is	And	Is	And	Is			ES
IF	R	M	H ₂ O	M	pH	A	Cl	A	SO ₄	A	CaCO ₃	M	THEN	U2	M
IF	R	M	H ₂ O	A	pH	M	Cl	M	SO ₄	M	CaCO ₃	A	THEN	U2	B
IF	R	B	H ₂ O	B	pH	A	Cl	A	SO ₄	B	CaCO ₃	B	THEN	U2	A
IF	R	B	H ₂ O	M	pH	B	Cl	M	SO ₄	M	CaCO ₃	A	THEN	U2	B
IF	R	M	H ₂ O	B	pH	M	Cl	M	SO ₄	B	CaCO ₃	M	THEN	U2	M
IF	R	B	H ₂ O	M	pH	A	Cl	M	SO ₄	A	CaCO ₃	B	THEN	U2	A
IF	R	B	H ₂ O	B	pH	B	Cl	B	SO ₄	B	CaCO ₃	B	THEN	U2	A

La evolución del algoritmo genético se puede apreciar en la figura 3.19, el ajuste del algoritmo a los valores de salida de U2 se detalla en la figura 3.20.

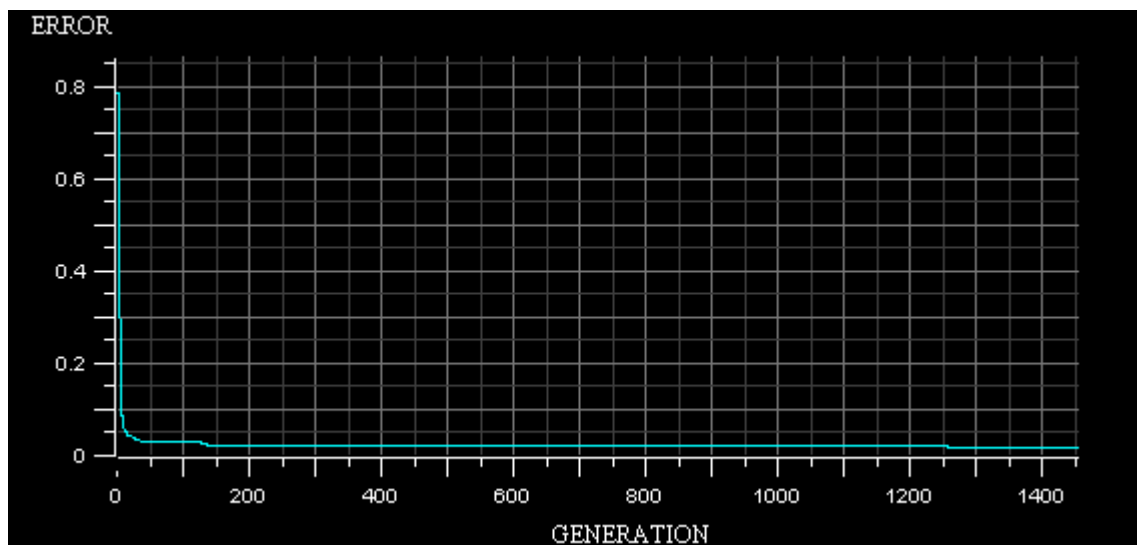


Figura 3.19 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de U2 en suelos de corrosividad media




Figura 3.20 Ajuste del algoritmo a los valores de salida de U2 durante la fase de entrenamiento del sistema basado en reglas para suelos de corrosividad media

3.1.2.2.3 Generación del sistema para U3

En el proceso de entrenamiento se obtuvieron tanto el ajuste de las funciones de pertenencia como la reducción del número de reglas de 343 a 10

Las funciones de pertenencia triangulares finales se pueden apreciar en la tabla 3.18.

Tabla 3.18 Funciones de pertenencia después del proceso de entrenamiento de los suelos de corrosividad media en la predicción del parámetro U3.

	BAJO	MEDIO	ALTO
Resistividad	25 – 28.3	26.2 – 28.6	27.4 – 31
Humedad	10 – 16.2	12.4 – 28.4	25.6 – 36
Ph	6 – 8.7	6.9 – 9.8	8.2 – 11
Cloruros	0.1 – 0.68	0.45 – 0.94	0.71 – 1.3
Sulfatos	0.1 – 0.73	0.2 – 0.99	0.63 – 1.4
Carbonato de	5.0 – 7.3	5.2 – 8.4	6.5 – 11.0

Calcio			
--------	--	--	--

Tabla 3.19 Sistema base de reglas borrosas para la predicción de U3 en suelos de corrosividad media

		Premisas											Consecuencia		
		Is	And	Is	And	Is	And	Is	And	Is	And	Is			ES
IF	R	B	H ₂ O	M	pH	A	Cl	A	SO ₄	B	CaCO ₃	B	THEN	U3	A
IF	R	A	H ₂ O	M	pH	B	Cl	A	SO ₄	M	CaCO ₃	A	THEN	U3	M
IF	R	M	H ₂ O	B	pH	M	Cl	M	SO ₄	A	CaCO ₃	M	THEN	U3	B
IF	R	M	H ₂ O	M	pH	A	Cl	M	SO ₄	B	CaCO ₃	B	THEN	U3	M
IF	R	A	H ₂ O	M	pH	M	Cl	B	SO ₄	A	CaCO ₃	M	THEN	U3	B
IF	R	B	H ₂ O	B	pH	B	Cl	B	SO ₄	B	CaCO ₃	B	THEN	U3	A
IF	R	M	H ₂ O	A	pH	M	Cl	A	SO ₄	M	CaCO ₃	B	THEN	U3	B
IF	R	A	H ₂ O	A	pH	B	Cl	M	SO ₄	B	CaCO ₃	A	THEN	U3	A
IF	R	A	H ₂ O	B	pH	A	Cl	B	SO ₄	B	CaCO ₃	A	THEN	U3	M
IF	R	B	H ₂ O	B	pH	M	Cl	A	SO ₄	M	CaCO ₃	M	THEN	U3	B

La evolución del algoritmo genético se puede apreciar en la figura 3.21, el ajuste del algoritmo a los valores de salida de U3 se detalla en la figura 3.22.

3.1.2.2.4 Predicción de B1

Se asumió que las constantes B tienen un comportamiento lógico similar a las U, por lo que se toman las mismas funciones de pertenencia y sólo se optimizan las reglas base

La aplicación del algoritmo arrojó como resultado la reducción del número de reglas a 7, tabla 3.20.




Figura 3.21 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de U3 en suelos de corrosividad media.




Figura 3.22 Ajuste del algoritmo a los valores de salida de U3 durante la fase de entrenamiento del sistema basado en reglas para suelos de corrosividad media.

Tabla 3.20 Sistema base de reglas borrosas para la predicción de B1 en suelos de corrosividad media.

	Premisas	Consecuencia
--	----------	--------------

		Is	And	Is	And	Is	And	Is	And	Is	And	Is			ES
IF	R	B	H ₂ O	B	pH	A	Cl	A	SO ₄	M	CaCO ₃	A	THEN	B1	B
IF	R	A	H ₂ O	A	pH	M	Cl	A	SO ₄	A	CaCO ₃	A	THEN	B1	A
IF	R	B	H ₂ O	M	pH	B	Cl	M	SO ₄	A	CaCO ₃	M	THEN	B1	M
IF	R	M	H ₂ O	B	pH	B	Cl	A	SO ₄	M	CaCO ₃	B	THEN	B1	B
IF	R	A	H ₂ O	A	pH	A	Cl	B	SO ₄	M	CaCO ₃	A	THEN	B1	A
IF	R	B	H ₂ O	B	pH	B	Cl	A	SO ₄	B	CaCO ₃	B	THEN	B1	M
IF	R	A	H ₂ O	B	pH	A	Cl	B	SO ₄	A	CaCO ₃	M	THEN	B1	B

La evolución del algoritmo genético se puede apreciar en la figura 3.23, el ajuste del algoritmo a los valores de salida de B1 se detalla en la figura 3.24.




Figura 3.23 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de B1 en suelos de corrosividad media.




Figura 3.24 Ajuste del algoritmo a los valores de salida de B1 durante la fase de entrenamiento del sistema basado en reglas para suelos de corrosividad media

3.1.2.2.5 Predicción de B2

La aplicación del algoritmo arrojó como resultado la reducción del número de reglas a 7, tabla 3.21.

Tabla 3.21 Sistema base de reglas borrosas para la predicción de B2 en suelos de corrosividad media

	Premisas												Consecuencia		
		Is	And	Is	And	Is	And	Is	And	Is	And	Is			ES
IF	R	A	H ₂ O	A	pH	B	Cl	M	SO ₄	B	CaCO ₃	M	THEN	B2	B
IF	R	B	H ₂ O	A	pH	A	Cl	M	SO ₄	M	CaCO ₃	A	THEN	B2	M
IF	R	B	H ₂ O	M	pH	B	Cl	B	SO ₄	A	CaCO ₃	A	THEN	B2	A
IF	R	M	H ₂ O	M	pH	B	Cl	A	SO ₄	B	CaCO ₃	B	THEN	B2	M
IF	R	A	H ₂ O	A	pH	M	Cl	B	SO ₄	M	CaCO ₃	M	THEN	B2	A
IF	R	M	H ₂ O	B	pH	M	Cl	A	SO ₄	A	CaCO ₃	B	THEN	B2	B
IF	R	A	H ₂ O	B	pH	B	Cl	M	SO ₄	B	CaCO ₃	A	THEN	B2	M

La evolución del algoritmo genético se puede apreciar en la figura 3.25, el ajuste del algoritmo a los valores de salida de B2 se detalla en la figura 3.26.




Figura 3.25 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de B2 en suelos de corrosividad media.

3.1.2.2.6 Predicción de B3

La aplicación del algoritmo arrojó como resultado la reducción del número de reglas a 4, tabla 3.22.

La evolución del algoritmo genético se puede apreciar en la figura 3.27, el ajuste del algoritmo a los valores de salida de B3 se detalla en la figura 3.28.




Figura 3.26 Ajuste del algoritmo a los valores de salida de B2 durante la fase de entrenamiento del sistema basado en reglas para suelos de corrosividad media

Tabla 3.22 Sistema base de reglas borrosas para la predicción de B3 en suelos de corrosividad media

	Premisas												Consecuencia		
		Is	And	Is	And	Is	And	Is	And	Is	And	Is			ES
IF	R	B	H ₂ O	A	pH	B	Cl	M	SO ₄	B	CaCO ₃	A	THEN	B3	A
IF	R	M	H ₂ O	B	pH	M	Cl	A	SO ₄	M	CaCO ₃	M	THEN	B3	M
IF	R	A	H ₂ O	M	pH	B	Cl	B	SO ₄	A	CaCO ₃	B	THEN	B3	B
IF	R	M	H ₂ O	A	pH	M	Cl	B	SO ₄	A	CaCO ₃	B	THEN	B3	B

3.1.2.2.7 Predicción de IL

La aplicación del algoritmo arrojó como resultado la reducción del número de reglas a 8, tabla 3.23.




Figura 3.27 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de B3 en suelos de corrosividad media.




Figura 3.28 Ajuste del algoritmo a los valores de salida de B3 durante la fase de entrenamiento del sistema basado en reglas para suelos de corrosividad media

Tabla 3.23 Sistema base de reglas borrosas para la predicción de IL en suelos de corrosividad media

Premisas												Consecuencia		
	Is	And	Is	And	Is	And	Is	And	Is	And	Is			ES

IF	R	B	H ₂ O	A	pH	B	Cl	A	SO ₄	A	CaCO ₃	A	THEN	B3	B
IF	R	B	H ₂ O	M	pH	B	Cl	B	SO ₄	B	CaCO ₃	M	THEN	B3	M
IF	R	B	H ₂ O	B	pH	A	Cl	M	SO ₄	A	CaCO ₃	A	THEN	B3	M
IF	R	M	H ₂ O	A	pH	B	Cl	B	SO ₄	A	CaCO ₃	B	THEN	B3	B
IF	R	A	H ₂ O	A	pH	B	Cl	M	SO ₄	B	CaCO ₃	B	THEN	B3	A
IF	R	M	H ₂ O	B	pH	M	Cl	A	SO ₄	M	CaCO ₃	M	THEN	B3	M
IF	R	M	H ₂ O	M	pH	A	Cl	M	SO ₄	B	CaCO ₃	A	THEN	B2	A
IF	R	A	H ₂ O	A	pH	M	Cl	A	SO ₄	A	CaCO ₃	B	THEN	B1	B

La evolución del algoritmo genético se puede apreciar en la figura 3.29, el ajuste del algoritmo a los valores de salida de IL se detalla en la figura 3.30.




Figura 3.29 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de IL en suelos de corrosividad media

En los suelos de corrosividad media se observó un alto grado de correlación entre los parámetros predecidos por el algoritmo y los datos experimentales de entrenamiento y validación, lo cual era de esperarse pues en estos suelos la reacción de corrosión sigue un patrón regular que facilita su predicción [16].

3.1.2.3 Grupo de suelos de corrosividad alta

Al algoritmo genético que potencia la optimización del sistema se ajustaron los parámetros iniciales como se aprecia en la tabla 3.28.




Figura 3.30 Ajuste del algoritmo a los valores de salida de IL durante la fase de entrenamiento del sistema basado en reglas para suelos de corrosividad media

3.1.2.3.1 Generación del sistema para U1

La aplicación del algoritmo arrojó como resultado el ajuste de las funciones de pertenencia modificando el conjunto L. Adicionalmente redujo el número de reglas a 10.

Las funciones de pertenencia triangulares finales se pueden apreciar en la tabla 3.25.

Tabla 3.24 Parámetros iniciales del algoritmo genético que optimiza al sistema basado en reglas para predecir las constantes U1, U2, U3, B1, B2, B3 y IL en el grupo de suelos de corrosividad media.

Parámetro	Valor
Número de generaciones máximo	1400

Población inicial	15
Probabilidad de cruce	0.01
Probabilidad de mutación	0.5
Probabilidad de ajuste uno/cero	0.01
Umbral de semejanza	0.001

Tabla 3.25 Funciones de pertenencia después del proceso de entrenamiento de los suelos de corrosividad alta en la predicción del parámetro U1.

	BAJO	MEDIO	ALTO
Resistividad	25 – 27.5	26.9 – 28.8	27.9 – 32
Humedad	8 – 15.3	10.6 – 30.4	25.7 – 37
Ph	5 – 7.8	6.8 – 10.4	9.2 – 12
Cloruros	0.2 – 0.69	0.55 – 0.83	0.76 – 0.99
Sulfatos	0.0 – 1.23	0.65 – 1.82	1.4 – 2.2
Carbonato de Calcio	4.0 – 6.19	5.04 – 8.67	7.2 – 11.0

En la tabla 3.26 se describen las reglas generadas por el algoritmo.

Tabla 3.26 Sistema base de reglas borrosas para la predicción de U1 en suelos de corrosividad alta

	Premisas												Consecuencia		
		Is	And	Is	And	Is	And	Is	And	Is	And	Is			ES
IF	R	B	H ₂ O	M	pH	B	Cl	M	SO ₄	A	CaCO ₃	B	THEN	U1	A
IF	R	M	H ₂ O	B	pH	A	Cl	A	SO ₄	M	CaCO ₃	M	THEN	U1	A
IF	R	B	H ₂ O	A	pH	B	Cl	B	SO ₄	A	CaCO ₃	B	THEN	U1	A
IF	R	A	H ₂ O	A	pH	A	Cl	B	SO ₄	A	CaCO ₃	A	THEN	U1	B
IF	R	M	H ₂ O	M	pH	M	Cl	A	SO ₄	B	CaCO ₃	M	THEN	U1	M
IF	R	B	H ₂ O	M	pH	M	Cl	M	SO ₄	A	CaCO ₃	A	THEN	U1	M
IF	R	M	H ₂ O	B	pH	A	Cl	B	SO ₄	M	CaCO ₃	M	THEN	U1	B
IF	R	A	H ₂ O	A	pH	A	Cl	M	SO ₄	A	CaCO ₃	B	THEN	U1	B
IF	R	A	H ₂ O	A	pH	B	Cl	B	SO ₄	M	CaCO ₃	A	THEN	U1	M

IF	R	B	H ₂ O	M	pH	B	Cl	A	SO ₄	B	CaCO ₃	B	THEN	U1	A
----	---	---	------------------	---	----	---	----	---	-----------------	---	-------------------	---	------	----	---

La evolución del algoritmo genético se puede apreciar en la figura 3.31, el ajuste del algoritmo a los valores de salida de U1 se detalla en la figura 3.32.




Figura 3.31 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de U1 en suelos de corrosividad alta.




Figura 3.32 Ajuste del algoritmo a los valores de salida de U2 durante la fase de entrenamiento del sistema basado en reglas para suelos de corrosividad alta.

3.1.2.3.2 Generación del sistema para U2

En el proceso de entrenamiento se obtuvieron tanto el ajuste de las funciones de pertenencia como la reducción del número de reglas de 343 a 8.

Las funciones de pertenencia triangulares finales se pueden apreciar en la tabla 3.27, no se observan cambios radicales en los rangos de las funciones triangulares.

Tabla 3.27 Funciones de pertenencia después del proceso de entrenamiento de los suelos de corrosividad alta en la predicción del parámetro U2.

	BAJO	MEDIO	ALTO
Resistividad	25 – 28.1	26.5 – 29.1	28.6 – 32
Humedad	8 – 18.6	12.8 – 33.3	26.2 – 37
Ph	5 – 7.5	4.5 – 11.4	9.7 – 12
Cloruros	0.2 – 0.59	0.45 – 0.83	0.52 – 0.99
Sulfatos	0.0 – 1.5	0.8 – 2.0	1.16 – 2.2

Carbonato de Calcio	de	4.0 – 6.4	5.4 – 9.9	7.4 – 11.0

En la tabla 3.28 pueden apreciar las reglas generadas por el algoritmo. Se observa nuevamente que al igual que en los rangos de las funciones de pertenencia, el pH toma mayor relevancia en el sistema de reglas borrosas.

Tabla 3.28 Sistema base de reglas borrosas para la predicción de U2 en suelos de corrosividad alta

		Premisas											Consecuencia		
		Is	And	Is	And	Is	And	Is	And	Is	And	Is			ES
IF	R	B	H ₂ O	A	pH	A	Cl	M	SO ₄	M	CaCO ₃	M	THEN	U2	A
IF	R	A	H ₂ O	A	pH	B	Cl	M	SO ₄	A	CaCO ₃	B	THEN	U2	A
IF	R	B	H ₂ O	B	pH	A	Cl	A	SO ₄	M	CaCO ₃	B	THEN	U2	A
IF	R	M	H ₂ O	B	pH	A	Cl	A	SO ₄	A	CaCO ₃	A	THEN	U2	A
IF	R	B	H ₂ O	M	pH	M	Cl	B	SO ₄	B	CaCO ₃	M	THEN	U2	M
IF	R	M	H ₂ O	M	pH	B	Cl	M	SO ₄	B	CaCO ₃	B	THEN	U2	B
IF	R	B	H ₂ O	A	pH	B	Cl	A	SO ₄	M	CaCO ₃	M	THEN	U2	B
IF	R	A	H ₂ O	A	pH	A	Cl	B	SO ₄	A	CaCO ₃	A	THEN	U2	B

La evolución del algoritmo genético se puede apreciar en la figura 3.33, el ajuste del algoritmo a los valores de salida de U2 se detalla en la figura 3.34.




Figura 3.33 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de U2 en suelos de corrosividad alta.

3.1.2.3.3 Generación del sistema para U3

En el proceso de entrenamiento se obtuvieron tanto el ajuste de las funciones de pertenencia como la reducción del número de reglas de 343 a 8.

Las funciones de pertenencia triangulares finales se pueden apreciar en la tabla 3.33.




Figura 3.34 Ajuste del algoritmo a los valores de salida de U2 durante la fase de entrenamiento del sistema basado en reglas para suelos de corrosividad alta

Tabla 3.29 Funciones de pertenencia después del proceso de entrenamiento de los suelos de corrosividad alta en la predicción del parámetro U3.

	BAJO	MEDIO	ALTO
Resistividad	25 – 27.5	25.9 – 28.5	27.2 – 32
Humedad	8 – 13.4	10.3 – 30.4	25.6 – 37
Ph	5 – 7.6	6.8 – 10.3	9.2 – 12
Cloruros	0.2 – 0.69	0.55 – 0.73	0.66 – 0.99
Sulfatos	0.0 – 1.23	0.65 – 1.82	1.4 – 2.2
Carbonato de Calcio	4.0 – 6.19	5.04 – 8.57	7.2 – 11.0

Tabla 3.30 Sistema base de reglas borrosas para la predicción de U3 en suelos de corrosividad alta

	Premisas	Consecuencia
--	----------	--------------

		Is	And	Is	And	Is	And	Is	And	Is	And	Is			ES
IF	R	A	H ₂ O	A	pH	B	Cl	A	SO ₄	B	CaCO ₃	B	THEN	U3	A
IF	R	M	H ₂ O	B	pH	M	Cl	A	SO ₄	M	CaCO ₃	A	THEN	U3	A
IF	R	A	H ₂ O	M	pH	B	Cl	B	SO ₄	A	CaCO ₃	M	THEN	U3	M
IF	R	A	H ₂ O	B	pH	A	Cl	B	SO ₄	B	CaCO ₃	B	THEN	U3	A
IF	R	B	H ₂ O	M	pH	A	Cl	A	SO ₄	A	CaCO ₃	A	THEN	U3	B
IF	R	M	H ₂ O	A	pH	M	Cl	A	SO ₄	M	CaCO ₃	B	THEN	U3	M
IF	R	B	H ₂ O	M	pH	A	Cl	M	SO ₄	B	CaCO ₃	A	THEN	U3	B
IF	R	B	H ₂ O	B	pH	M	Cl	A	SO ₄	M	CaCO ₃	B	THEN	U3	M

La evolución del algoritmo genético se puede apreciar en la figura 3.35, el ajuste del algoritmo a los valores de salida de U3 se detalla en la figura 3.36.




Figura 3.35 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de U3 en suelos de corrosividad alta.




Figura 3.36 Ajuste del algoritmo a los valores de salida de U3 durante la fase de entrenamiento del sistema basado en reglas para suelos de corrosividad alta.

3.1.2.3.4 Predicción de B1

Se asumió que las constantes B tienen un comportamiento lógico similar a las U, por lo que se toman las mismas funciones de pertenencia y sólo se optimizan las reglas base.

La aplicación del algoritmo arrojó como resultado la reducción del número de reglas a 4, tabla 3.31.

Tabla 3.31 Sistema base de reglas borrosas para la predicción de B1 en suelos de corrosividad alta.

	Premisas												Consecuencia		
		Is	And	Is	And	Is	And	Is	And	Is	And	Is			ES
IF	R	M	H ₂ O	M	pH	B	Cl	M	SO ₄	B	CaCO ₃	M	THEN	B1	B
IF	R	B	H ₂ O	B	pH	B	Cl	B	SO ₄	A	CaCO ₃	A	THEN	B1	A
IF	R	M	H ₂ O	A	pH	M	Cl	B	SO ₄	M	CaCO ₃	A	THEN	B1	A
IF	R	A	H ₂ O	B	pH	M	Cl	B	SO ₄	A	CaCO ₃	M	THEN	B1	M

La evolución del algoritmo genético se puede apreciar en la figura 3.37, el ajuste del algoritmo a los valores de salida de B1 se detalla en la figura 3.38.

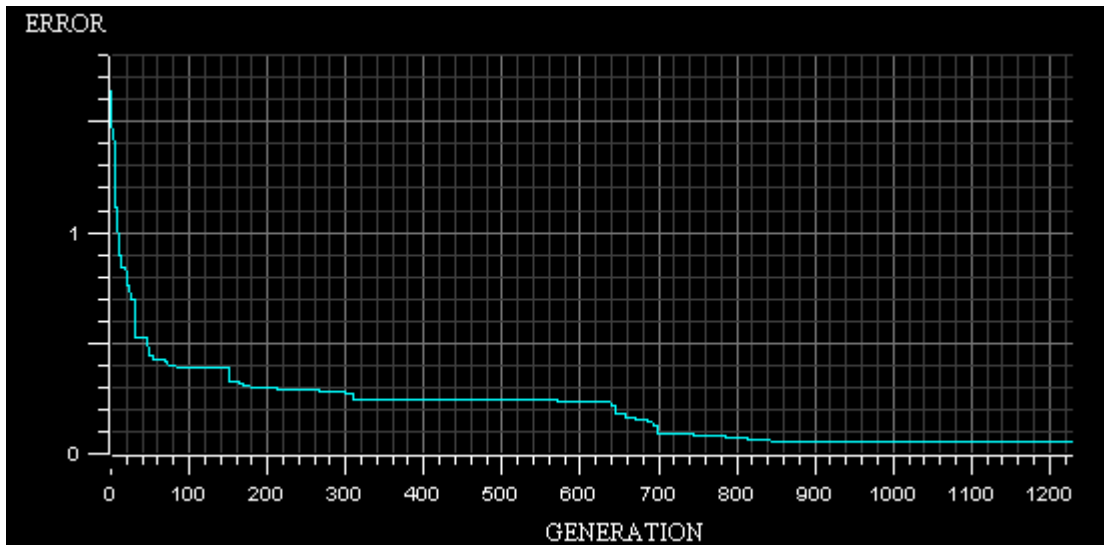


Figura 3.37 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de B1 en suelos de corrosividad alta.




Figura 3.38 Ajuste del algoritmo a los valores de salida de B1 durante la fase de entrenamiento del sistema basado en reglas para suelos de corrosividad alta

3.1.2.3.5 Predicción de B2

La aplicación del algoritmo arrojó como resultado la reducción del número de reglas a 6, tabla 3.36.

Tabla 3.32 Sistema base de reglas borrosas para la predicción de B2 en suelos de corrosividad alta

	Premisas												Consecuencia		
		Is	And	Is	And	Is	And	Is	And	Is	And	Is			ES
IF	R	B	H ₂ O	M	pH	A	Cl	B	SO ₄	B	CaCO ₃	A	THEN	B2	M
IF	R	B	H ₂ O	A	pH	A	Cl	A	SO ₄	M	CaCO ₃	B	THEN	B2	B
IF	R	B	H ₂ O	B	pH	A	Cl	B	SO ₄	M	CaCO ₃	M	THEN	B2	B
IF	R	A	H ₂ O	M	pH	M	Cl	N	SO ₄	B	CaCO ₃	B	THEN	B2	A
IF	R	M	H ₂ O	A	pH	B	Cl	B	SO ₄	M	CaCO ₃	B	THEN	B2	B
IF	R	M	H ₂ O	A	pH	A	Cl	M	SO ₄	A	CaCO ₃	M	THEN	B2	A

La evolución del algoritmo genético se puede apreciar en la figura 3.39, el ajuste del algoritmo a los valores de salida de B2 se detalla en la figura 3.40.




Figura 3.39 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de B2 en suelos de corrosividad alta.

3.1.2.3.6 Predicción de B3

La aplicación del algoritmo arrojó como resultado la reducción del número de reglas a 6 tabla 3.33.

La evolución del algoritmo genético se puede apreciar en la figura 3.41, el ajuste del algoritmo a los valores de salida de B3 se detalla en la figura 3.42.




Figura 3.40 Ajuste del algoritmo a los valores de salida de B2 durante la fase de entrenamiento del sistema basado en reglas para suelos de corrosividad alta

Tabla 3.33 Sistema base de reglas borrosas para la predicción de B3 en suelos de corrosividad alta

		Premisas											Consecuencia		
		Is	And	Is	And	Is	And	Is	And	Is	And	Is			ES
IF	R	B	H ₂ O	A	pH	B	Cl	B	SO ₄	A	CaCO ₃	A	THEN	B3	M
IF	R	A	H ₂ O	A	pH	B	Cl	B	SO ₄	B	CaCO ₃	B	THEN	B3	A
IF	R	M	H ₂ O	M	pH	M	Cl	A	SO ₄	M	CaCO ₃	M	THEN	B3	B
IF	R	A	H ₂ O	A	pH	B	Cl	B	SO ₄	B	CaCO ₃	B	THEN	B3	B
IF	R	M	H ₂ O	M	pH	M	Cl	A	SO ₄	A	CaCO ₃	M	THEN	B3	M

IF	R	B	H ₂ O	B	pH	A	Cl	B	SO ₄	M	CaCO ₃	A	THEN	B3	A
----	---	---	------------------	---	----	---	----	---	-----------------	---	-------------------	---	------	----	---




Figura 3.41 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de B3 en suelos de corrosividad alta.




Figura 3.42 Ajuste del algoritmo a los valores de salida de B3 durante la fase de entrenamiento del sistema basado en reglas para suelos de corrosividad alta

3.1.2.3.7 Predicción de IL

La aplicación del algoritmo arrojó como resultado la reducción del número de reglas a 5, tabla 3.34.

Tabla 3.34 Sistema base de reglas borrosas para la predicción de IL en suelos de corrosividad alta

		Premisas											Consecuencia		
		Is	And	Is	And	Is	And	Is	And	Is	And	Is			ES
IF	R	B	H ₂ O	A	pH	B	Cl	A	SO ₄	A	CaCO ₃	A	THEN	B3	A
IF	R	A	H ₂ O	B	pH	A	Cl	M	SO ₄	M	CaCO ₃	M	THEN	B3	B
IF	R	B	H ₂ O	M	pH	M	Cl	M	SO ₄	A	CaCO ₃	A	THEN	B3	B
IF	R	M	H ₂ O	M	pH	B	Cl	A	SO ₄	B	CaCO ₃	M	THEN	B3	M
IF	R	M	H ₂ O	A	pH	B	Cl	M	SO ₄	A	CaCO ₃	B	THEN	B3	A

La evolución del algoritmo genético se puede apreciar en la figura 3.43, el ajuste del algoritmo a los valores de salida de IL se detalla en la figura 3.44.




Figura 3.43 Error Vs Número de generaciones de la evolución del algoritmo en la predicción de IL en suelos de corrosividad alta

En los suelos de corrosividad media se observó un alto grado de correlación entre los parámetros predcidos por el algoritmo y los datos experimentales de entrenamiento y validación, lo cual era de esperarse pues en estos suelos la reacción de corrosión sigue un patrón regular que facilita su predicción [16].

El algoritmo correlacionó los parámetros de la curva de polarización del acero en suelos de alta corrosividad, aún cuando la mayoría de los coeficientes de correlación estuvieron por debajo de 0.96, también es destacable el ligero aumento en el número de reglas generadas lo que es un indicativo de la complejidad del sistema corrosivo y de que se presentan efectos sinérgicos entre los distintos parámetros controlados, sin embargo, es muy poca la información útil que se puede extraer de las reglas generadas, y en algunos casos aparentemente incoherente. Ello confirma el poco conocimiento que se tiene sobre la interacción de las diversas variables que intervienen en el proceso.




Figura 3.44 Ajuste del algoritmo a los valores de salida de IL durante la fase de entrenamiento del sistema basado en reglas para suelos de corrosividad alta

3.2 Optimización de la protección catódica

Las curvas de polarización predichas por el algoritmo se utilizaron para simular y optimizar la protección catódica de una tubería enterrada.

Para validar el comportamiento del algoritmo de solución de elementos de contorno aplicados a la protección catódica, se simuló el primer tramo de la tubería Pulin con una longitud de 5Km, los datos del suelo de este tramo se pueden apreciar en la tabla 3.35. Al momento de realizar el estudio el tramo de tubería estaba protegido por un sistema de protección catódica por corriente impresa consistente en una cama de 4 electrodos conectados a un rectificador que los mantiene a un voltaje de 900 mV y con una corriente de 2,5A. La cama se ubica a 10 m de la porción central del tramo del ducto.

Tabla 3.35 Parámetros fisicoquímicos del suelo en el cual se encuentra enterrado el primer tramo del ducto Pulín

Resistividad d	% Agua	pH	[Cl-] meq/100 g	[SO4-2] meq/100 g	%CaCO3
28,15	35,02	8,22	0,37460	0,11723	5,90

El algoritmo de agrupamiento catalogó al suelo como de alta corrosividad, posteriormente el sistema de reglas borrosas para suelos de alta corrosividad determinó que la curva de polarización tendría la forma de la ecuación (3.2).

$$J = e^{(U - -684.6\text{mV}) / 22\text{mV} / \text{dec}} - \left(\frac{1}{80.03\mu\text{A} / \text{cm}^2} + \frac{1}{e^{(U - -480.63\text{mV}) / 220.5\text{mV} / \text{dec}}} \right)^{-1} - e^{-(U - -692.36\text{mV}) / 48\text{mV} / \text{dec}} \quad (3.2)$$

Esta configuración se cargó al algoritmo de solución descrito en la sección 2.2.1.1, el perfil de potenciales generados por el algoritmo y los encontrados en el tramo se pueden apreciar en la figura 3.45. El coeficiente de correlación fue de 0.9081. La baja de correlación entre los potenciales calculados y los reales se debe posiblemente a irregularidades en el suelo o la tubería no reportados en el estudio del ducto pues el perfil del potencial real no muestra la simetría esperada.




Figura 3.45 Perfil de potenciales calculados numéricamente y potenciales encontrados en el tramo uno de la tubería Pulín.

Para saber si el sistema de protección catódica fue diseñado y opera de forma óptima, se aplica el algoritmo descrito en la sección 2.2.2. El número de electrodos fue de tres, pero se le permite al programa moverlos sobre una línea ubicada a 10 metros de distancia de la tubería. Los parámetros del algoritmo genético se muestran en la tabla 3.36. El resultado del cálculo numérico se puede apreciar en la figura 3.46, y la convergencia del algoritmo se puede apreciar en la figura 3.47

Tabla 3.36 Parámetros iniciales del algoritmo genético que optimiza al sistema de protección catódica del primer tramo de la tubería de Pulín.

Parámetro	Valor
Número de generaciones máximo	400
Población inicial	30
Probabilidad de cruce	0.01
Probabilidad de mutación	0.5




Figura 3.46 Perfil de potenciales calculados numéricamente en el primer tramo de la tubería Pulin.

El programa encontró que las posiciones óptimas de los electrodos deberían ser 612, 2533 y 4210 metros, mantenidos a un potencial de 400mV y con corrientes de 1.89A.

La configuración propuesta por el programa difiere ostensiblemente de la que se aplica actualmente en dicho ducto y los principales efectos de la configuración propuesta son una distribución de potenciales más homogénea y una disminución en el consumo de corriente.

4. CONCLUSIONES

Fue posible categorizar los suelos arcillosos a partir de su resistividad, pH; concentraciones de cloruros, sulfatos y carbonatos; y porcentaje de humedad, utilizando la técnica de agrupamiento borroso, prediciendo así la corrosividad del suelo.

Por primera vez se pudo predecir mediante un sistema basado en reglas borrosas, la curva de polarización de un metal enterrado en un suelo utilizando para ello sólo las características fisicoquímicas del suelo categorizado previamente según su corrosividad, obteniendo coeficientes de correlación entre 0.92 y 0.999 con los datos experimentales.

Se demostró que es posible utilizar las curvas de polarización predichas mediante la metodología propuesta, para la simulación y optimización de sistemas de protección catódica de tuberías enterradas.

5. RECOMENDACIONES

Si bien la metodología propuesta para predecir las curvas de polarización, fue validada con éxito en suelos arcillosos su aplicación a suelos de otro tipo es evidente puesto que es un hecho conocido que todo tipo de suelo puede ser categorizado en clusters y cada uno de ellos produce una polarización diferente en el metal lo que sugiere una inmediata aplicabilidad de la metodología desarrollada.

El algoritmo de extracción de parámetros de la curva de polarización experimental probó ser una herramienta útil en el ajuste de datos experimentales a modelos teóricos, es necesario ahondar en este tipo de algoritmos y extender su aplicación a otras situaciones de ingeniería como podría ser el caso de los estudios cinéticos de reacciones químicas.

Los estudios de la variación de la composición de los suelos en el tiempo, sugieren que esta permanece relativamente constante a excepción del porcentaje de humedad, por lo que estudiar el acoplamiento de la metodología de predicción de curvas de polarización con un sistema de información climático podría ser útil para predecir las curvas en tiempo casi real sin necesidad de experimentación.

6. REFERENCIAS BIBLIOGRÁFICAS

[1] ZAMANI N. G., Boundary element simulation of the cathodic protection system in a prototype ship, En: Applied Mathematics and Computation Vol 26, Is 2 , 1988, p 119-134.

[2] AOKI S. y KISHIMOTO K., Prediction of galvanic corrosion rates by the boundary element method, En: Mathematical and Computer Modelling, Vol 15, Is 3-5, 1991, p 11-22.

[3] LEE S. H., TOWNLEY D. W. y ESHUN O., A Boundary element model of cathodic well Casing protection, En: Journal of Computational Physics, Vol 107, Is 2 , 1993, p 338-347.

[4] BRICHAU F., and DECONICK F., A numerical model for cathodic protection of buried pipes, Corrosion, Vol 50 No 1 pp39-49, 1994.

[5] STEVEN HOU L. y WEIWEI SUN, Optimal positioning of anodes for cathodic protection, En: SIAM Journal on Control and Optimization, Vol 34, N 3, 1996, p 855-873.

[6] AOKI S. and AMAYA K., Optimization of cathodic protection system by BEM, In: Engineering Analysis with Boundary elements, No 19, 1999, p 147-156.

[7] AOKI S. y AMAYA K., Effective boundary element methods in corrosion analysis, En: Engineering analysis with boundary elements, 2003, p507-519.

- [8] MILTIADOU P., and WROBEL L., Optimization of cathodic protection systems using boundary elements and genetic algorithms, En: Corrosion, 2002, p 912-921.
- [9] WROBEL L. y MILTIADOU P, Genetic algorithms for inverse cathodic protection problems, En: Engineering analysis with boundary elements, 2002, p 969-972.
- [10] SANTANA E. y ADEY R., Optimising the location of anodes in cathodic protection systems to smooth potential distribution, En: Advances in Engineering Software, Vol 36, Is 9 , 2005, p 591-598.
- [11] SANTIAGO J. A. y TELLES J. C., A solution technique for cathodic protection with dynamic boundary conditions by the boundary element method, En: Advances in Engineering Software, Vol 30, Is 9-11 , 1999, p 663-671.
- [12] DIVO, KASSAB, y RODRIGUEZ, Characterization of the BEM to chromium electroplating simulation and to identification of experimental polarization laws, En: Engineering analysis with Boundary Elements, N 24, 2000, p 615-622.
- [13] DRUESNE F., PAUMELLEA P. y VILLONB P., Determination of the laws of polarization by coupling measurements with numerical tool, En: Journal of Materials Processing Technology, Vol 118, Is 1-3 , 2001, p 368-370.
- [14] MILTIADOU P. y WROBEL L., A BEM –based identification for polarization curves in cathodic protection systems, En: International Journal for Numeric Methods in Engineering, 2003, p 814-828.
- [15] CHRISHOLM E., GRAY L., y GILES, Solution of Nonlinear polarization boundary conditions, En: Electronic Journal of boundary elements, Vol 1, No 3, 2003, p 418-438.

[16] SONG G., CAO C., and LIN H., A New Technique for Correlation of Underground Corrosion. En: Corrosion, Vol 51, No 7, 1997, p 491-497.

[17] PHAM T., Modeling of Fuzzy System in Geotechnical Engineering. En: IEEE Trans on Geotechnical Engineering, Vol 44, 2002, p 254-263.

[18] TALEB A., STAFIE J. Y BADIALI J. P., Numerical simulation of metal corrosion with cluster formation, En: Transactions on Engineering Sciences, Vol 48, Simulation of Electrochemical Processes, 2005, p 288-296.

[19] BARD A. and FAULKNER L., Electrochemical Methods, New Yor, John Wiley and Sons, 1980. 27 p.

[20] WROBEL L.C., The boundary element method, Vol 1. New York, John Wiley and Sons, 2002. 216, 223 p.

[21] BREBBIA D., The boundary element method for engineers and scientist. 3 Ed., New York, John Wiley and Sons, 1996. 123p.

[22] GOLDBERG D., Genetic Algorithms in Search, optimization and Machine Learning, Reading, Addison – Wesley, MA, 1989. 48-98 p.

[23] KAINULAINEN K., Clustering Algorithms: Basics and Visualization, In: <http://niksula.cs.hut.fi/~jkinula/pdfs/clustering.pdf>, 2003, 3-30 p.

[24] CHIN-TENG L. and LEE G., Neural Fuzzy System. A Neural-Fuzzy Synergism to Intelligent Systems, Upper Saddle River, Prentice Hall, 2002, 182-202 p.