

**METODOLOGÍA PARA ESTIMAR EL ÁNGULO DE FRICCIÓN INTERNA
UTILIZANDO TÉCNICAS DE INTELIGENCIA ARTIFICIAL QUE INTEGREN
DATOS DE LABORATORIO CON PERFILES ELÉCTRICOS**



LEIDY JULIANA DELGADO HERNÁNDEZ

**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICOQUÍMICAS
ESCUELA DE INGENIERÍA DE PETRÓLEOS
BUCARAMANGA**

2012

**METODOLOGÍA PARA ESTIMAR EL ÁNGULO DE FRICCIÓN INTERNA
UTILIZANDO TÉCNICAS DE INTELIGENCIA ARTIFICIAL QUE INTEGREN
DATOS DE LABORATORIO CON PERFILES ELÉCTRICOS**

LEIDY JULIANA DELGADO HERNÁNDEZ

**Trabajo de grado presentado como requisito para optar el título de:
Ingeniero de Petróleos**

**Director:
ING. FERNANDO ENRIQUE CALVETE, MSC**

**Codirector:
ING. JENNY MABEL CARVAJAL, MSC.**

**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FISCOQUÍMICAS
ESCUELA DE INGENIERÍA DE PETRÓLEOS
BUCARAMANGA**

2012

DEDICATORIA

A Dios, por haberme permitido llegar hasta este punto y haberme dado salud para lograr mis objetivos, además de su infinita bondad y amor.

A mi mamá, por haberme apoyado en todo momento, por sus consejos, por sus valores, por la motivación constante que me ha permitido ser una persona de bien pero más que nada por su amor.

A mi papá por los ejemplos infundidos día a día, por el valor mostrado para salir adelante y por su amor.

A mi hermana por ser el ejemplo de una hermana mayor y de la cual aprendí de aciertos y momentos difíciles al igual por el respaldo recibido de mis hermanos Ricardo y Jhon.

A mis amigos, sin su ayuda incondicional y desinteresada no hubiera podido llevar a cabo mis aspiraciones, además por ser parte no solo de apoyo académico si no que también emocional; Andres

F, Andres M, Carlos, Cristian C, John, Greyssi, Lina y Victor...

Los quiero mucho ☺.

LEIDY JULIANA

AGRADECIMIENTOS

Al **GRUPO DE INVESTIGACIÓN DE ESTABILIDAD DE POZO**, por brindarme la oportunidad de contribuir en la mejora del conocimiento aplicativo.

A la ingeniera **JENNY MABEL CARVAJAL, ING. FERNANDO CALVETE Y EL ING. DIEGO SUAREZ**, por ser el apoyo fundamenta en el desarrollo de este proyecto, por guiarme y brindarme su amplia colaboración.

A los geólogos **MARIA DEL PILAR MARIN y ERICK JOHAN ILLIDGE ARAUJO**, por el aporte en el conocimiento brindado en su campo de aplicación.

A los ingenieros **LAURA VIVIANA GALVIS CARREÑO y CESAR AUGUSTO OCHOA**, por el ser la guía en la aplicación de tecnologías informáticas.

CONTENIDO

	Pág.
INTRODUCCIÓN.....	18
1 CRITERIO DE FALLA DE MOHR – COULOMB.....	19
2 ÁNGULO DE FRICCIÓN INTERNA.....	23
3 MÉTODOS PARA LA DETERMINACIÓN DEL ÁNGULO DE FRICCIÓN INTERNA.....	25
3.1 PRUEBAS TRIAXIALES.....	25
3.1.1 ANÁLISIS DE LA PRUEBA.....	27
3.1.2 TIPOS DE FALLAS PRESENTADOS EN UNA PRUEBA TRIAXIAL.....	30
3.2 VALORES AFI REFERENCIADOS EN LA LITERATURA.....	32
3.3 PROGRAMA AGE.....	34
4 PARÁMETROS INFLUYENTES EN LA DETERMINACIÓN DEL ÁNGULO DE FRICCIÓN INTERNA.....	35
4.1 COMPACIDAD.....	36
4.2 POROSIDAD.....	36
4.3 GRANULOMETRÍA.....	37
4.4 FORMA DE LAS PARTÍCULAS.....	39
4.5 HUMEDAD.....	40
4.6 ANISOTROPÍA.....	41
4.7 VOLUMEN DE ARCILLA.....	43
5 REGISTROS ELÉCTRICOS.....	45
5.1 REGISTRO DE DENSIDAD.....	45
5.2 CÁLCULO DE LA POROSIDAD.....	46
5.3 FACTORES QUE AFECTAN EL PERFIL.....	47
5.4 REGISTRO NEUTRÓN.....	49
5.4.1 DETERMINACIÓN DE LA POROSIDAD.....	51
5.5 FACTORES QUE AFECTAN EL PERFIL.....	53
5.6 REGISTRO SÓNICO.....	53
5.7 DETERMINACIÓN DE LA POROSIDAD.....	56
5.8 FACTORES QUE INFLUYEN EN LA MEDICIÓN.....	58
5.9 REGISTRO RAYOS GAMA.....	58
5.9.1 PRINCIPIO DE MEDICIÓN.....	59
5.9.2 EQUIPO.....	59

5.9.3	USOS DEL PERFIL DE RAYOS GAMMA.....	60
5.9.4	PROFUNDIDAD DE INVESTIGACIÓN.....	62
5.9.5	FACTORES QUE AFECTAN LA MEDIDA.....	62
5.10	REGISTRO CORE GAMMA.....	63
5.10.1	HERRAMIENTA.....	64
5.11	REGISTRO DE POTENCIAL ESPONTANEO.....	65
5.11.1	PRINCIPIO DE MEDICIÓN.....	66
5.11.2	CURVA DE POTENCIAL ESPONTANEO (SP).....	66
5.11.3	EQUIPO.....	68
5.12	REGISTROS ELÉCTRICOS RESISTIVOS.....	68
5.12.1	FACTORES QUE INFLUYEN EN LA MEDICIÓN.....	69
6	INTELIGENCIA ARTIFICIAL.....	71
6.1	GENERALIDADES.....	71
7	REDES NEURONALES ARTIFICIALES.....	74
7.1	ARQUITECTURAS DE REDES NEURONALES.....	74
7.2	REDES NEURONALES Y RECONOCIMIENTO DE PATRONES.....	76
7.2.1	PATRÓN.....	76
7.2.2	SISTEMA DE RECONOCIMIENTO DE PATRONES.....	77
7.2.3	APRENDIZAJE SUPERVISADO.....	78
7.2.4	APRENDIZAJE NO SUPERVISADO.....	78
7.3	UNIDADES EN REDES NEURONALES.....	78
7.4	ESTRUCTURA DE LAS REDES NEURONALES ARTIFICIALES.....	80
7.5	FUNCIONES DE ACTIVACIÓN.....	82
7.6	ENTRENAMIENTO DE LAS REDES NEURONALES ARTIFICIALES.....	83
7.6.1	ALGORITMO DE PROPAGACIÓN HACIA ATRÁS (BACKPROPAGATION).....	84
7.6.2	PROPAGACIÓN HACIA ATRÁS CON VARIACIÓN EN LA TASA DE APRENDIZAJE. 84	
7.6.3	PROPAGACIÓN HACIA ATRÁS RESILIENT (RPROP).....	85
7.6.4	ALGORITMO QUASI-NEWTON.....	85
7.6.5	ALGORITMO LEVENBERG-MARQUARDT.....	85
7.7	VENTAJAS QUE OFRECEN LAS RED NEURONALES.....	86
7.7.1	APRENDIZAJE ADAPTATIVO.....	87
7.7.2	AUTO-ORGANIZACIÓN.....	87
7.7.3	TOLERANCIA A FALLOS.....	88
7.7.4	OPERACIÓN EN TIEMPO REAL.....	89
7.7.5	FÁCIL INSERCIÓN DENTRO DE LA TECNOLOGÍA EXISTENTE.....	89
8	ALGORITMOS GENÉTICOS.....	90

8.1	ESQUEMA BÁSICO.....	91
8.2	PARÁMETROS DE LOS ALGORITMOS GENÉTICOS.....	92
8.3	OPERACIONES DE LOS ALGORITMOS GENÉTICOS.....	93
8.4	SELECCIÓN.....	95
8.4.1	SELECCIÓN POR RULETA.....	95
8.4.2	SELECCIÓN POR TORNEO.....	96
8.4.3	CRUCE.....	97
8.4.3.1	CRUCE DE 1 PUNTO.....	97
8.4.3.2	CRUCE DE 2 PUNTOS.....	98
8.4.3.3	CRUCE UNIFORME.....	99
8.4.4	MUTACIÓN.....	99
8.5	VENTAJAS DE LOS ALGORITMOS GENÉTICOS.....	100
8.6	DESVENTAJAS DE LOS ALGORITMOS GENÉTICOS.....	101
9	PARÁMETROS DE LAS RNA Y AG UTILIZADOS EN LA HERRAMIENTA DE APLICACIÓN.....	102
10	HERRAMIENTA DE INTELIGENCIA ARTIFICIAL ORION.....	108
11	GENERALIDADES DE LAS CUENCAS.....	115
11.1	CUENCA DE LOS LLANOS ORIENTALES Y PIEDEMONTE LLANERO.....	115
11.1.1	ESTRATIGRAFÍA.....	116
11.2	CUENCA DEL CATATUMBO.....	119
11.3	ESTRATIGRAFÍA.....	120
12	INFORMACIÓN DISPONIBLE PARA EL SECTOR DE APLICACIÓN.....	124
13	METODOLOGIA DE TRABAJO.....	126
13.1	ETAPA DE DOCUMENTACIÓN.....	126
13.2	ETAPA DE CLASIFICACIÓN.....	126
13.3	ETAPA DE ESTIMACIÓN DE REDES.....	130
13.4	ETAPA DE VALIDACIÓN DE LAS REDES.....	130
13.5	ETAPA DE ANÁLISIS DE LOS RESULTADOS.....	131
13.6	ETAPA DE APLICACIÓN.....	132
13.7	ETAPA DE VALIDACIÓN.....	132
13.8	ETAPA DE GENERACIÓN DE LA METODOLOGÍA.....	132
14	APLICACIÓN DEL ESQUEMA DE TRABAJO.....	133
14.1	ESTIMACIÓN DE REDES PARA LA VALIDACIÓN DE LOS ESQUEMAS EN EL POZO A1.....	133
14.1.1	ESQUEMA 1.....	134
14.1.2	PASOS EN LA ESTIMACIÓN DE LAS REDES:.....	134
14.1.3	ESQUEMA 2.....	141

14.1.4	ESQUEMA 3	145
14.1.5	ESQUEMA 4	147
14.1.6	ESQUEMA 5	150
14.2	APLICACIÓN DE ESQUEMAS PARA EL POZO P5	153
14.3	APLICACIÓN DE ESQUEMAS PARA EL POZO C3.....	158
14.4	ESTIMACIÓN DEL MENOR NÚMERO DE DATOS AFI A UTILIZAR EN LA APLICACIÓN.....	159
15	METODOLOGÍA PARA LA ESTIMACIÓN DEL ÁNGULO DE FRICCIÓN INTERNA.....	162
16	APLICACIÓN DE LA METODOLOGIA	165
17	CONCLUSIONES	168
	RECOMENDACIONES.....	170
	NOMENCLATURA.....	171
	BIBLIOGRAFIA.....	172
	ANEXO A	177

LISTA DE FIGURAS

	Pág.
Figura 1. Criterio de Mohr-Coulomb en el plano de los esfuerzos de corte y normal	22
Figura 2. Relación existente entre la fricción interna del material y el ángulo de fricción interna	23
Figura 3. Criterio de Mohr-Coulomb en el plano de los esfuerzos de corte y normal	24
Figura 4. Esquema de visualización de la cámara triaxial.	26
Figura 5. Muestra preparada para una prueba de celda triaxial.	27
Figura 6. Esquema de visualización de los esfuerzos distribuidos en la cámara triaxial.	29
Figura 7. Envolvente de falla múltiple.	30
Figura 8. Fallas obtenidas de una probeta de ensayo triaxial. A. Falla neta al corte, B. Falla parcial al corte, C. Deformación excesiva.....	31
Figura 9. Esquema de representación del programa AGE Versión 3.0 – [Litologic Classification]	34
Figura 10. Parámetros friccionantes de la roca	35
Figura 11. Relación entre el ángulo de fricción interna y la porosidad en rocas areniscas en el mar de norte.....	37
Figura 12. Relación entre el ángulo de fricción interna y la porosidad en rocas areniscas, para diferentes facies marinas	37
Figura 13. Distribución del tamaño de grano de las muestras 1, 2, 3, en donde D es la densidad de grano medida en milímetros y N es el porcentaje de dicho grano contenido en la muestra.	38
Figura 14. Distribución del tamaño de grano de las muestras 4, 5, 6, en donde D es la densidad de grano medida en milímetros y N es el porcentaje de dicho grano contenido en la muestra.	39
Figura 15. Resistencia al corte versus la humedad y el ángulo de fricción interno para un suelo Utisol de sabana franco arenoso del estado de Monagas.....	40
Figura 16. Relación del ángulo de ataque y el plano de debilidad.	43
Figura 17. Herramienta y principio de funcionamiento del Registro de Densidad.....	46
Figura 18. Esquema de visualización de la interacción entre los neutrones generados por la herramienta neutrón.....	50
Figura 19. Herramienta CNL de dos detectores (uno lejano y otro cerca a la fuente).	50
Figura 20. Herramienta de Registro Sónico.....	54
Figura 21. Tren de ondas recibidas por un registro sonoro.....	55
Figura 22. Esquema de funcionamiento de un equipo de Rayos Gamma	60
Figura 23. Correlación del registro de Rayos Gamma con el registro Core-Gamma) muestra la correlación entre un fondo de pozo y Core-Gamma registro de superficie.	63
Figura 24. Equipo Spectral Core Gamma de Corex	64

Figura 25. Método de medición del registro potencial espontaneo.	67
Figura 26. Medición del potencial espontaneo a lo largo de un pozo. A) esquema del circuito de medición. B) registro de potencial espontaneo en un pozo con un corte areno arcilloso.	68
Figura 27. Estructura de una Red Neuronal Artificial	75
Figura 28. Estructura de un nodo en una red neuronal.	79
Figura 29. Estructura del perceptrón multicapa.	81
Figura 30. Funciones de activación. A. función logística o log sigmoid. B. Función Gaussiana o Radias Basis. C. Función lineal. D. Función tangente hiperbólica o tansing.	83
Figura 31. Cruce de un punto.	98
Figura 32. Cruce de dos puntos.....	98
Figura 33. Cruce uniforme.	99
Figura 34. Diagrama de actividades para el diseño del mejor algoritmo genético de aplicación al mejor tipo de red neuronal.	103
Figura 35. Ventana inicial del programa de redes Neuronales.....	109
Figura 36. Carga de datos para detención temprana	110
Figura 37. Carga de parámetros del algoritmo genético	111
Figura 38. Ventana de configuraciones	112
Figura 39. Análisis general de la red	113
Figura 40. Extensión probardat.m.....	114
Figura 41. Salida de los datos a partir de la Extensión probardat.m	114
Figura 42. Ubicación de la cuenca de los Llanos Orientales.....	115
Figura 43. Modelo estratigráfico y sistemas petrolíferos de la cuenca de los Llanos Orientales	119
Figura 44 Columna estratigráfica generalizada de la Cuenca del Catatumbo.	123
Figura 45. Cuencas y Campos en los cuales se encuentran estimación AFI de laboratorio. ..	124
Figura 46. Set de registros disponibles que involucran las variables que afectan la estimación del AFI.	125
Figura 47. Metodología de trabajo parte 1.....	127
Figura 48. Metodología de trabajo parte 2.....	128
Figura 49. Configuración de la red neuronal para el esquema 1 a partir del primer grupo de datos en el pozo A1.	135
Figura 50. Configuración de la red neuronal para el esquema 1 a partir del primer grupo de datos en el pozo A1.	138
Figura 51. Datos de laboratorio AFI vs curva de estimación AFI calculado en conjunto con los registros presentes para la estimación, en el pozo A1- Esquema 1.	141
Figura 52. Configuración de la red neuronal para el esquema 2 en el pozo A1.	143
Figura 53. Datos de laboratorio AFI vs curva de estimación AFI calculado en conjunto con los registros presentes para la estimación, en el pozo A1 Esquema 2.....	144
Figura 54. Configuración de la red neuronal para el esquema 3 en el pozo A1.	145

Figura 55. Datos de laboratorio AFI vs curva de estimación AFI calculado en conjunto con los registros presentes para la estimación, en el pozo A1 Esquema 3.....	147
Figura 56. Configuración de la red neuronal para el esquema 4 en el pozo A1.	148
Figura 57. Datos de laboratorio AFI vs curva de estimación AFI calculada por la red en conjunto con los registros presentes para la estimación, en el pozo A1- Esquema 4.	149
Figura 58. Configuración de la red neuronal para el esquema 4 en el pozo A1.	151
Figura 59. Datos de laboratorio AFI vs curva de estimación AFI calculada por la red en conjunto con los registros presentes para la estimación, en el pozo A1- Esquema 5.	153
Figura 60. Configuración de la red neuronal para el esquema 4 en el pozo P4	155
Figura 61. Visualización de la curva de estimación AFI para el pozo P5	157
Figura 62. Registros eléctricos del pozo C3.	159
Figura 63. Estimación del menor número de datos estimados para la aplicación de la metodología	160
Figura 64. Posición de los pozos P5 y P6 pertenecientes a la Cuenca del Catatumbo.....	165
Figura 65. Visualización estructural de los pozos P5 y P6 pertenecientes a la Cuenca del Catatumbo.....	165
Figura 66. Visualización de la curva de estimación AFI para el pozo P6.	166

LISTA DE TABLAS

	Pág.
Tabla 1. Valores típicos de parámetros de resistencia para rocas.....	32
Tabla 2. Ángulo de fricción y cohesión de algunas rocas.....	33
Tabla 3. Mediciones AFI para diferentes clasificaciones de tamaño de grano relacionadas con la densidad de la mima en gm/cm ³	39
Tabla 4. Densidad promedio de una unidad de formación (principales litologías).	47
Tabla 5. Densidad promedio del fluido de perforación (filtrado de lodo).	47
Tabla 6. Algunos Valores de Δt y V para diferentes tipos de roca.	56
Tabla 7. Configuración ayuda para la configuración del algoritmo genético en el entrenamiento de las redes neuronales.....	107
Tabla 8. Datos seleccionados para el entrenamiento de las Redes Neuronales en el Pozo A1.	133
Tabla 9. Datos seleccionados para el primer grupo de entrenamiento de las Redes Neuronales en la herramienta ORION TM para el Pozo A1 (e=entrenamiento, v=verificación).....	135
Tabla 10. Configuración de la red neuronal para el primer grupo de entrenamiento en el pozo A1 - Esquema 1.	136
Tabla 11. Datos seleccionados para el segundo grupo de entrenamiento de las Redes Neuronales en la herramienta ORION TM para el Pozo A1 (e=entrenamiento, v=verificación).	137
Tabla 12. Error relativo porcentual entre el AFI medido en laboratorio y el AFI estimado por la herramienta ORION TM para el pozo A1- Esquema 1.....	138
Tabla 13. Error relativo porcentual entre el AFI medido en laboratorio y el AFI estimado por medio de RNA para el pozo A1- Esquema 1.....	139
Tabla 14. Configuración de la red neuronal para los pozos A1 - Esquema 2.	142
Tabla 15. Error relativo porcentual entre el AFI medido en laboratorio y el AFI estimado por medio de RNA para el pozo A1- Esquema 2.....	143
Tabla 16. Configuración de la red neuronal para el pozo A1- Esquema 3.....	146
Tabla 17. Error relativo porcentual entre el AFI medido en laboratorio y el AFI estimado por medio de RNA para el pozo A1- Esquema 3.....	146
Tabla 18. Configuración de la red neuronal para el pozo A1- Esquema 4.....	148
Tabla 19. Error relativo porcentual entre el AFI medido en laboratorio y el AFI estimado para el pozo A1- Esquema 4.....	149
Tabla 20. Configuración de la red neuronal para el pozo A1- Esquema 5.....	151
Tabla 21. Error relativo porcentual entre el AFI medido en laboratorio y el AFI estimado para el pozo A1- Esquema 5.....	152

Tabla 22. Datos seleccionados para el primer grupo de entrenamiento de las Redes Neuronales en la herramienta ORION™ para el Pozo P4 (e=entrenamiento, v=verificación).	154
Tabla 23. Configuración del mejor tipo de red generada por la herramienta Orion para el pozo P4	156
Tabla 24. Error relativo medido entre los datos de entrenamiento y los generados por la red para el pozo P5	156
Tabla 25. Estimación del menor número de datos AFI para la aplicación de la metodología en el pozo A1.	160
Tabla 26. Error relativo porcentual para la estimación del menor número de datos AFI para la aplicación de la metodología en el pozo A1.	161

RESUMEN

TITULO: METODOLOGÍA PARA ESTIMAR EL ANGULO DE FRICCIÓN INTERNA UTILIZANDO TÉCNICAS DE INTELIGENCIA ARTIFICIAL QUE INTEGREN DATOS DE LABORATORIO CON PERFILES ELÉCTRICOS.*

AUTOR: LEIDY JULIANA DELGADO HERNANDEZ.**

PALABRAS CLAVES: Angulo de fricción interna, parámetros friccionantes, registros eléctricos.

Un modelo geomecánico lleva consigo la evaluación de diferentes propiedades, las cuales determinan una parte esencial en la predicción de la inestabilidad de un pozo. Los obstáculos y limitaciones en la valoración exacta de los modelos se encuentran sujetos entre otros aspectos a la buena estimación o valoración de las propiedades las cuales deben ser exactas y precisas. Actualmente, el ángulo de fricción – una de esas propiedades – es uno de los parámetros críticos con mayor incertidumbre.

Existen pocos métodos disponibles para medir o estimar el ángulo de fricción interna (AFI) de la roca in situ. Mediciones en corazones y correlaciones obtenidas a partir de registros de pozo, son los métodos más utilizados. Sin embargo el mayor inconveniente en la valoración directa de corazones se encuentra previsto en el estado de conservación pleno de la roca, para lo cual en rocas no consolidadas esta descripción es casi imposible de obtener y para las correlaciones obtenidas estas pueden ser aplicables con algunas restricciones del tipo de roca en estudio.

En este trabajo se estudia y evalúa los parámetros friccionantes de la roca a partir de los cuales y basados en tecnologías alternativas como herramientas software se genera una metodología de estimación AFI a partir de registros eléctricos y datos de laboratorio, aplicado a pozos Colombianos; disminuyendo las dificultades presentes actualmente en la medición y mejorando a su vez el cálculo.

* Trabajo de grado.

** Facultad de Ingenierías Físicoquímicas. Ingeniería de Petróleos. Director: Ing. Fernando Enrique Calvete, Co director: Ing. Jenny Mabel Carvajal.

ABSTRACT

TITLE: METHODOLOGY FOR ESTIMATING THE ANGLE OF INTERNAL FRICTION USING TECHNIQUES OF ARTIFICIAL INTELLIGENCE WHICH MAKE UP (INTEGRATE) ELECTRICAL PROFILES AND LABORATORY DATA. *

AUTHOR: LEIDY JULIANA DELGADO HERNANDEZ. **

KEY WORDS: angle of internal friction, frictional parameters, electrical logs.

A geomechanical model involves the evaluation of different properties, which determine an essential part in predicting wellbore instability. Obstacles and limitations in the accurate assessment of the models are subject, among other things, to a good estimation or evaluation of properties which must be accurate and precise. Currently, the angle of internal friction - one of those properties - is one of the critical parameters with greater uncertainty.

There are few available methods to measure or estimate the angle of internal friction (AFI) of the rock in situ. Measurements in plugs and correlations obtained from well logs are the most commonly methods used. But the biggest drawback in the direct assessment of plugs is the full conservation of the rock, for which in unconsolidated rock this description is almost impossible to obtain and the correlations obtained can be applied with some restrictions of rock type under study.

This work reviews and evaluates the frictional parameters of the rock from which and based on alternative technologies such as software tools, it generates an AFI estimation methodology from electric logs and laboratory data, applied to Colombian wells; reducing currently difficulties in measurements and improving in turn the calculation.

* Research work.

** Faculty of Physical – Chemical Engineering. Petroleum Engineering School. Director: Ing. Fernando Enrique Calvete, Co- director: Ing. Jenny Mabel Carvajal.

INTRODUCCIÓN

Problemas de estabilidad asociados a geomecánica producen tiempos no productivos y costos adicionales. Los modelos geomecánicos ayudan a mitigar y prevenir esos problemas, pero requieren de datos de propiedades mecánicas que deben ser exactas y precisas. Actualmente, el ángulo de fricción – una de esas propiedades – es uno de los parámetros críticos con mayor incertidumbre.

El ángulo de fricción interna (AFI), es obtenido principalmente a partir de pruebas triaxiales realizadas a muestras cilíndricas recolectadas en la zona de interés. Dichas pruebas de laboratorio proporcionan puntos de datos discretos en toda la sección del pozo generando consigo grandes costos y problemas en la representatividad de la roca relacionados con la extracción y tratamiento de la misma. Como solución a este problema diferentes autores plantean métodos para la medición, como valores de AFI constantes para arenas y arcillas respectivamente de acuerdo con los cutofs y de Vshl o metodologías para el cálculo de correlaciones que permiten la determinación AFI para diferentes tipos de roca, a partir de la porosidad y/o volumen de shale obtenidas de registros eléctricos.

Sin embargo aunque los nuevos métodos de solución reducen los costos y permiten generar de manera más sencilla la sección de medición en todo el pozo, estos valores resultan ser poco precisos debido a que permiten un amplio rango para las arenas arcillosas, definiéndose aun la no existencia de un método de determinación AFI eficiente por lo que se requiere desarrollar métodos que permitan su aproximación de manera más acertada, mejorando la exactitud de los modelos de estabilidad.

1 CRITERIO DE FALLA DE MOHR – COULOMB

En la mecánica de suelos actual, la teoría de falla más utilizada es lo que podría considerarse una combinación de dos teorías clásicas, el criterio de rotura de Mohr y la ley de Coulomb.

La aplicación del criterio de Mohr - Coulomb en la predicción de fallas de corte en la estabilidad de pozo proporciona resultados bastante precisos; lo que junto con su facilidad para aplicarlo lo han convertido en el criterio más popular, para el cálculo del ángulo de fricción interna y el UCS.

En este modelo, solamente se utiliza el esfuerzo efectivo máximo y el esfuerzo efectivo mínimo (representados en el esfuerzo normal y de corte con respecto al plano de falla) para predecir la falla (PALACIOS, J Y HERNÁNDEZ G. 2008). El criterio se basa en que la cedencia y/o falla debe ocurrir cuando el esfuerzo de corte exceda la suma de la resistencia cohesiva del material (S_o) y la resistencia friccional de los planos de deslizamiento expresado como:

$$\tau = S_o + \mu\sigma_n \quad [1]$$

Donde τ es el esfuerzo de corte, σ es el esfuerzo normal, S_o es la resistencia cohesiva de la roca.

El significado del criterio es el siguiente: si en el plano de una roca el esfuerzo de cizalla supera la resistencia que la roca opone a la ruptura, debida a la cohesión entre las partículas que la componen y además, es capaz de vencer la fuerza rozamiento que se opone al deslizamiento de los dos bloques de roca a ambos lados de dicho plano, la roca se romperá por él.

La ecuación 1 describe una recta, llamada línea de fracturación representada por la ecuación anterior. Esta fórmula plateada tuvo su origen en las observaciones de Amonto cuando sometía las muestras de rocas a compresión, y fallas, que por lo general presentaban analogías a la situación donde el bloque está en estado de movimiento inminente en un plano inclinado,

a partir de eso define el coeficiente de fricción μ , entre el bloque y el plano, y lo relaciono con el ángulo del mismo Φ , al cual lo llamo ángulo de fricción.

$$\tau = S_0 + \sigma \tan(\phi) \quad [2]$$

El criterio de Coulomb es una línea recta en el plano τ - σ , cuyo intercepto es S_0 y la pendiente es la tangente de ϕ . La línea o envoltura divide el plano τ - σ en dos regiones; una estable por debajo de esta y una región de falla por encima de ella misma.

En el momento de falla; se interceptan la envoltura y el círculo de Mohr en un punto del plano τ - σ . (Ver **Figura 1**). Se define β como el ángulo de falla, reescribiendo luego las ecuaciones de esfuerzo de cizalla y esfuerzo normal en función del ángulo y de los esfuerzos principales reescribiendo el criterio de falla como:

$$\sigma_1 = C_0 + \sigma_3 \tan\beta^2 \quad [3]$$

Que expresa que la falla ocurrirá cuando el esfuerzo principal máximo σ_1 sea mayor que la suma de la resistencia compresiva uniaxial C_0 (o esfuerzo compresivo uniaxial mas grande que puede ser aplicado a un material sin que este falle) y el producto del esfuerzo principal mínimo σ_3 (presión de confinamiento) con la tangente del ángulo de falla al cuadrado.

Características de los círculos de Mohr¹:

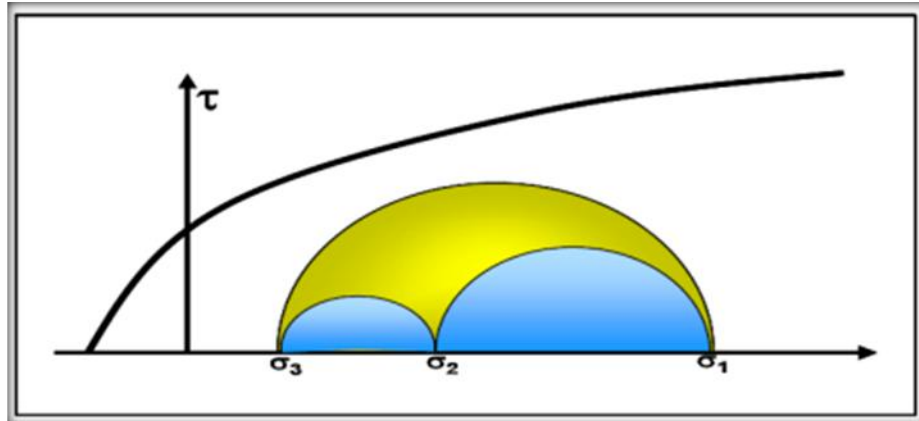
- ◆ El círculo de Mohr (Ver **Figura 1**), llamada también “Curva de Ruptura Experimental” (línea negra) permite representar el estado de esfuerzos

¹ ROZO, A. 2008. Desarrollo de una metodología para determinar el ángulo de fricción interna a partir del volumen de arcilla y la porosidad obtenidos de los registros eléctricos. Proyecto de grado presentado ante la Universidad Industrial de Santander (Bucaramanga, Colombia), como requisito para obtener el título de ingenieros de Petróleos.

principales en el mismo plano ($T - \sigma$) donde se grafica la envolvente del criterio de Mohr-Coulomb (circulo amarillo) el cual representa los máximos esfuerzos de corte que pueden ser soportados por el material en el momento de ruptura.

- ◆ Los esfuerzos principales y el ángulo de fricción interna son obtenidos de pruebas de laboratorio (triaxiales), y no se tiene en cuenta el esfuerzo intermedio.
- ◆ Cualquier coordenada en el círculo representa un plano a través del cual se interesa conocer el estado de esfuerzos.
- ◆ Para graficar el círculo; el centro se encuentra dado por el promedio de los esfuerzos principales.
- ◆ El radio se encuentra dado por el promedio de la diferencia de los esfuerzos.
- ◆ El esfuerzo al cual falla la roca es una medida de su resistencia, por consiguiente el diámetro del círculo de Mohr representa el esfuerzo diferencial $(\sigma_1 - \sigma_2/2)$ representando que a mayor diámetro mayor resistencia del material.
- ◆ El ángulo θ si se mide en sentido contrario a las manecillas de reloj en una compresión y es positivo. En sentido de las manecillas del reloj bajo tensión es negativo.
- ◆ El máximo esfuerzo de corte esta dado en un ángulo de 45° .
- ◆ Por convención, cualquier campo de esfuerzos que fomente el deslizamiento a lo largo de un plano de fractura, el cual estando orientado favorablemente, será de compresión si el círculo de Mohr se grafica en el cuadrante de la derecha. En el caso contrario si es un campo de esfuerzos de tensión el círculo quedara en el cuadrante de la izquierda.

Figura 1. Criterio de Mohr-Coulomb en el plano de los esfuerzos de corte y normal



Fuente. Modificado de E, FJAER. 1996. Petroleum related rock mechanics, 2nd ed. ELSEVIER.

La teoría de falla de Mohr – Coulomb permite, en general llegar a resultados bastante satisfactorios en las aplicaciones de la mecánica de suelos a los problemas prácticos, pero indudablemente no es una teoría perfecta en el sentido de que no permite predecir todas las fallas observadas ni explica toda la evidencia experimental disponible. Quizá la explicación de estas deficiencias estribe en que esta teoría posee una deficiencia básica, si se acepta que la falla de un material se produce como consecuencia del estado de esfuerzos que actué en su interior. En efecto, es sabido que dicho estado de esfuerzos puede describirse a final de cuentas por tres parámetros independientes σ_1 , σ_2 y σ_3 : en general, un estado de esfuerzos no puede describirse por completo con menos de tres parámetros independientes. Pues bien, la teoría de Mohr – Coulomb relaciona la falla con el esfuerzo actuante, el cual se relaciona con la diferencia de los esfuerzos principales máximo y mínimo, pero no toma en cuenta el esfuerzo principal intermedio, σ_2 . De esta manera la teoría de falla no puede aspirar a cubrir en forma completa todos los casos de falla reales, por no tomar en cuenta su totalidad las causas de falla.

Sin embargo la experimentación actual parece indicar que el valor del esfuerzo σ_2 en la falla influye en cierta medida en los parámetros de resistencia $S_0 +$ y Φ que puedan obtenerse en el laboratorio, si bien probablemente está influenciada es moderada.

2 ÁNGULO DE FRICCIÓN INTERNA


El ángulo de fricción interna, se encuentra estrechamente relacionado con la fricción interna del material, definida como la resistencia al deslizamiento causado por la fricción que hay entre las superficies de contacto de las partículas y su densidad.

La fricción interna (Ver **Figura 2**), está definida por el ángulo cuya tangente es la relación entre la fuerza que resiste el deslizamiento F_c , a lo largo de un plano y la fuerza normal (N) aplicada a dicho plano.

Encontrándose el ángulo de fricción interna y el coeficiente de fricción interna relacionados de la siguiente forma:

$$\tan \phi = \frac{F_c}{N} \quad [4]$$

Figura 2. Relación existente entre la fricción interna del material y el ángulo de fricción interna




Fuente: <http://www.ingenieracivil.com>

Siendo entonces definido el ángulo de fricción como la medida de la capacidad de una masa de roca para soportar una fuerza cortante, es el ángulo medido entre la fuerza normal y la fuerza resultante, que es alcanzado justo antes de que ocurra la ruptura en respuesta al esfuerzo cortante y definida por Mohr

Coulomb (Ver **Figura 3**) como el ángulo que se forma entre el plano horizontal con la línea de falla (Mantilla, A. Garnica P. 2003):

$$\tan \phi = \mu \quad [5]$$

Figura 3. Criterio de Mohr-Coulomb en el plano de los esfuerzos de corte y normal



Fuente. GARCÍA, M. Determinación de la orientación y magnitud del esfuerzo máximo horizontal a partir del modelamiento de breakouts en la zona del piedemonte llanero colombiano. UIS.2006.

3 MÉTODOS PARA LA DETERMINACIÓN DEL ÁNGULO DE FRICCIÓN INTERNA

La determinación del ángulo de fricción interna se basa principalmente de datos obtenidos de ensayos de laboratorio conocido como ensayos triaxiales, en los que se caracteriza el comportamiento tensión-deformación de la roca, permitiendo así que se ejecute un estudio detallado de las propiedades que puedan afectar la estabilidad de la misma en el pozo, sin embargo no es la única forma por la cual se puede determinar AFI ya que también existen correlaciones que tienen en cuenta el contenido de shales en la formación a examinar; siendo la más utilizada y confiable hasta el momento la realizada por medio de pruebas triaxiales.


3.1 PRUEBAS TRIAXIALES

El estudio de la línea de resistencia intrínseca, o envolvente de Mohr, puede llevarse a cabo por medio de la prueba de compresión triaxial.

La cámara o prensa triaxial es un equipo utilizado en el laboratorio para la realización de ensayos de deformación de rocas. Metodología creada por Hoek y Franklin en 1968.

La cámara triaxial (Ver **Figura 4**) está compuesta por: pistón, deformímetro, rodamientos del pistón de carga, barras inferiores de acoplamiento, barras exteriores de acoplamiento, cilindro, fluido de confinamiento, muestra de suelo, membrana, rodamientos inferiores, sistema de drenaje de la muestra, caja electrónica manométrica, sensor de presión (presión de poros), sensor de diferencias de presión, columna de referencia, sensor presión cámara y columna de medición.

Figura 4. Esquema de visualización de la cámara triaxial.




Fuente. F.G.H. BLYTH AND M.H. DE FREITAS. Geology for Engineers, Seventh Edition. ELSEVIER.

La preparación de la prueba (Ver **Figura 5**) consiste en el aislamiento de la muestra de suelo a evaluar con una membrana impermeable, colocándolas dentro de una celda triaxial aislada del fluido que es contenido en la cámara evitando que se disgregue la muestra cuando se rompa llamado también fluido de confinamiento.

Una vez montada la prueba el pistón que debe ser de un material resistente como el acero con dureza mínima especificada en las normas ASTM en la parte superior se desplaza hacia la muestra una vez se inicia la prueba. Las conexiones en los extremos de la muestra permiten el drenaje del agua y aire desde los vacíos de la roca o la medición de la presión de poros bajo condiciones no drenado.

Figura 5. Muestra preparada para una prueba de celda triaxial.



Fuente. F.G.H. BLYTH AND M.H. DE FREITAS. Geology for Engineers, Seventh Edition. ELSEVIER.

Si no se permite drenaje, se puede medir la presión de poro. Realizando varias pruebas se puede obtener la envolvente de Mohr para un suelo determinado. Sin embargo cuando la muestra es compuesta de material blando, el pistón de acero no es recomendable y se considera elegir a gusto de quien realiza la prueba un material que se ajuste a los requerimientos de grosor, radio y dureza del material a utilizar. La funda a utilizar debe ser lo suficientemente blanda como para no proporcionar un apoyo significativo siendo a su vez de unos pocos milímetros y hecho de caucho plástico o teflón con el fin de mejorar la exactitud de las mediciones.

3.1.1 Análisis de la prueba.

Los ensayos triaxiales son utilizados para calcular las características esfuerzo-deformación y de resistencia de las rocas. Teóricamente son pruebas en que se podrían variar a voluntad las presiones actuantes en tres direcciones ortogonales sobre un espécimen de roca, efectuando mediciones sobre sus características mecánicas en forma completa.

Sin embargo en realidad y buscando sencillez en la realización de las pruebas, dos de las tres tensiones actuantes son iguales cuando la probeta utilizada es cilíndrica.

Una vez montada la muestra el pistón es accionado hidráulicamente y transmite un esfuerzo variable en la dirección vertical. El estado de esfuerzo creado artificialmente es, por lo tanto, triaxial de tipo axial (σ_1), es decir su elipsoide de esfuerzo es de revolución, con los esfuerzos horizontales iguales en todas las direcciones (σ_2, σ_3) (iguales a la presión de la cámara) (Ver **Figura 6**). Por supuesto esto actúa no solo en la superficie vertical de la muestra, sino también en sus bases. Por lo tanto si la carga axial aplicada por el pistón es P y la sección transversal de la muestra es A, entonces:


$$\sigma_1 = \frac{P}{A} + \sigma_3 \quad [6]$$

$$\frac{P}{A} = \sigma_1 - \sigma_3 \quad [7]$$

La razón P/A es, por ende, igual a la diferencia entre las tensiones principales mayor y menor $\sigma_1 - \sigma_3$, y se denomina tensión desviante σ_d .

La prueba finaliza al fallar la muestra, siendo leído en manómetros la presión confinante y el esfuerzo vertical. El desplazamiento del pistón es mostrado por un indicador y, a partir del cual conociendo la longitud inicial de la muestra pueden calcularse las elongaciones que suelen proyectarse como porcentajes. Muchas prensas o cámaras realizan directamente una proyección carga-desplazamiento en registradores gráficos incorporados. Los aparatos más completos incluyen la posibilidad de medir también cambios en la anchura, por medio de sensores eléctricos muy sensibles llamados transductores. Además algunos aparatos permiten calentar la muestra a distintas temperaturas e incluso conectar la muestra con fluidos de distintas composiciones que pueden influir en la deformación.

Figura 6. Esquema de visualización de los esfuerzos distribuidos en la cámara triaxial.



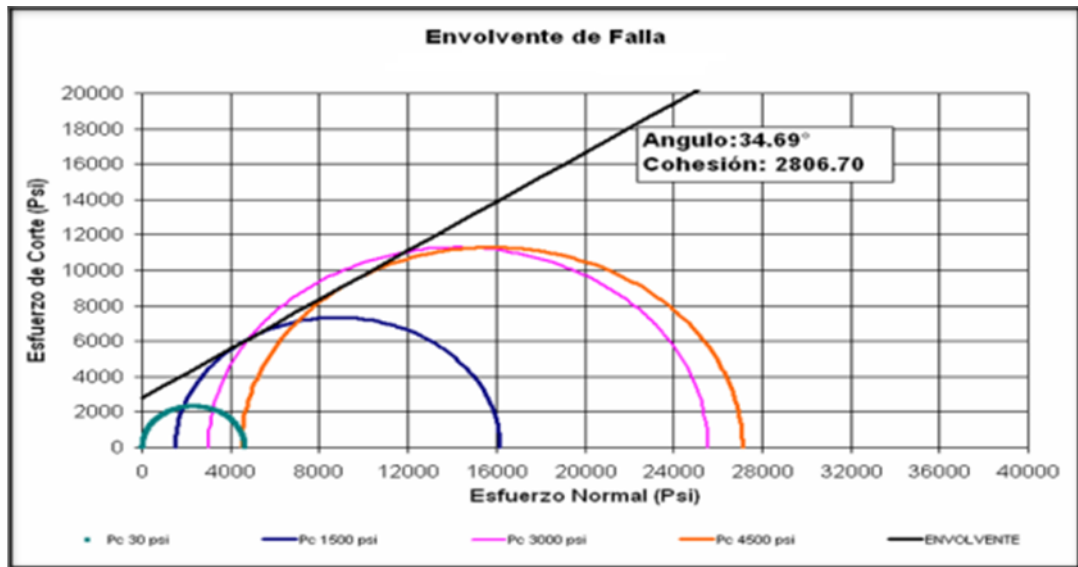
Fuente. ROZO, A. Desarrollo de una metodología para determinar el ángulo de fricción interna a partir del volumen de arcilla y la porosidad obtenidos de los registros eléctricos. UIS. 2008.

Una vez analizados los esfuerzos aplicados a la muestra se procede a graficar por medio de un software las envolventes de falla múltiple, como se muestra en la **Figura 7**, y como su nombre lo indica el esquema de visualización de diferentes envolventes de falla tomadas a diferentes presiones de confinamiento, lo cual permite conocer de manera acertada la región de falla de la muestra que a su vez facilita la obtención del ángulo de fricción interna, bajo el criterio de falla de Mohr Coulomb.

El ángulo de fricción interna se determina de la misma forma que las envolventes por medio de programas que permiten calcular la tangente a la curva (círculos de Mohr) y a su vez trazar la horizontal de donde es medido el AFI.

La forma de la envolvente de falla varía con el material, según este sea granular, cohesivo o intermedio. Para un mismo suelo depende de su relación de vacíos, grado de saturación y tipo de prueba.

Figura 7. Envolvente de falla múltiple.



Fuente. Ecopetrol. Laboratorio de rocas. Instituto Colombiano del Petróleo. ICP.

3.1.2 Tipos de fallas presentados en una prueba triaxial.

La falla de una muestra puede producirse de diferentes maneras durante el ensayo triaxial, como se observa en la **Figura 8**.


La aplicación de la presión isotrópica y la tensión desviante constituyen dos etapas diferentes del ensayo. La posibilidad de variar las características de estas etapas y sus condiciones de drenaje permiten desarrollar distintos tipos de ensayos triaxiales, así estos pueden dividirse según la siguiente clasificación:

- ◆ Ensayo no consolidado no drenado: recibe también el nombre de ensayo rápido (UU), no se presenta durante la prueba drenaje por lo que no se presenta disminución en la presión de poro durante la aplicación de la presión isotrópica σ_3 , la muestra se falla aplicando rápidamente la carga axial (sin drenaje).
- ◆ Ensayo consolidado no drenado: recibe también el nombre de ensayo consolidado rápido (CU), se presenta el drenaje durante la aplicación de la presión de la cámara, de modo que varíe la presión de poro y la

muestra se consolida bajo dicha presión de cámara. La presión de confinamiento se transforma en efectiva σ_3 . No se permite el drenaje durante la aplicación de la tensión desviante.

- ◆ Ensayo consolidado no drenado con medición de presión neutra: se denomina (C U) □, Este tipo de ensayo es similar al CU con la diferencia que durante la etapa de aplicación de la tensión desviante se procede a la medición de la presión neutra, permitiendo esto obtener la presión efectiva en cada momento del ensayo.
- ◆ Ensayo consolidado drenado: recibe también el nombre de ensayo lento (S), en este tipo se permite el drenaje durante las dos etapas de la prueba triaxial de manera que se tiene una consolidación bajo la presión de cámara, transformándose la presión en efectiva y el exceso de presión de poro se disipa durante la aplicación lenta de la tensión desviante.

Figura 8. Fallas obtenidas de una probeta de ensayo triaxial. A. Falla neta al corte, B. Falla parcial al corte, C. Deformación excesiva



Fuente. ROZO, A. Desarrollo de una metodología para determinar el ángulo de fricción interna a partir del volumen de arcilla y la porosidad obtenidos de los registros eléctricos. UIS. 2008.

3.2 VALORES AFI REFERENCIADOS EN LA LITERATURA

Actualmente para obtener valores AFI se utilizan tablas propuestas en la literatura, en los que se les asigna un valor correspondiente dependiendo del tipo de roca a tratar, variando desde las arcillas hasta las arenas limpias.

Diferentes autores basan sus resultados en estudios teniendo en cuenta el contenido de shale de la roca (Ver **Tabla 1**) y en otros caracterizando diferentes tipos de roca en laboratorio (Ver **Tabla 2**).

Esta técnica presenta muy baja precisión debido a que propone un amplio rango de valores en su mayoría a las arenas arcillosas, es decir para un volumen determinado de shale existe una amplia gama de opciones de ángulo de fricción interna que posibilita en gran medida la selección de un valor poco representativo de este.

Tabla 1. Valores típicos de parámetros de resistencia para rocas

Tipo de Roca	Peso unitario seco KN/m ³	Cohesión Mpa	Ángulo de fricción Φ
Rocas Ígneas Duras: granito basalto	25 – 30	35 – 55	35 – 45
Rocas Metamórficas: cuarcitas, gneis, pizarras	25 – 28	20 – 40	30 – 40
Rocas Sedimentarias Duras: calizas, dolomitas, areniscas	23 – 28	10 – 30	35 – 45
Rocas Sedimentarias Blandas: areniscas, lutitas, limonitas	17 – 23	1 – 20	25 – 35

Fuente. HOEK, E. & BRAY, JW, 1981, Rock Slope Engineering, 3d. Edition, London: Institute of Mining and Metallurgy. Pag 22.

Tabla 2. Ángulo de fricción y cohesión de algunas rocas

Descripción	Porosidad (%)	Si (Mpa)	Φ	Rango de presión de confinamiento (Mpa)
Barea Sandstone	18.2	27.2	27.8	0 – 200
Barlesville sandstone		8.0	37.2	0 – 203
Pottville sandstone	14.0	14.9	45.2	0 – 68.9
Repetto siltstone	5.6	34.7	32.1	0 – 200
Muddy shale	4.7	38.4	14.4	0 – 200
Stockton shale		0.34	22.0	0.8 – 4.1
Edmonton bentonitic shale (water content 30%)	44.0	0.3	7.5	0.1 – 3.1
Sioux quartzite		70.6	48.0	0 – 203
Texas slate; loaded 30 to cleavage		26.2	21.0	34.5 – 276
90 to cleavage		70.3	29.9	34.5 – 276
Georgia marble	0.3	21.2	25.3	5.6 – 68.9
Wolf Camp limestone		23.6	34.8	0 – 203
India limestone	19.4	6.72	42.0	0 – 9.6
Hasmark dolomite	3.5	22.8	35.5	0.8 – 5.9
Chalk	40.0	0	31.5	10 – 90
Blaine anhydrite		43.4	29.4	0 – 203
Inada biotite granite	0.4	55.2	47.7	0.1 – 98
Stone Mountain granite	0.2	55.1	51.0	0 – 68.9
Nevada Test Side basalt	4.6	66.2	31.0	3.4 – 34.5
Schistone gneiss	0.5			
90 to schistocity	1.9	46.9	28.0	0 – 69
30 to schistocity		14.8	27.6	0 – 69

Fuente. Goodman, Richard E. 1980. Introduction to rock mechanics

3.3 PROGRAMA AGE

Otro método de referencia propiedad del Instituto Colombiano del Petróleo - ICP, es el programa AGE, que contiene una selección de diferentes tipos de rocas para dos valores específicos de ángulo de fricción interna – 40 para arenas y 25 para arcillas- reduciendo el rango de valores aplicables a un tipo de roca. (Ver **Figura 9**)

Figura 9. Esquema de representación del programa AGE Versión 3.0 – [Litologic Classification]

LITOLGY	CODE
Sand (SS)	1
Sandstone (SS)	2
Sandstone Claystone (SSCL)	3
Claystone (CL)	4
Claystone Sandstone (CLSS)	5
Slime (SL)	6
Shale (SH)	7
Limestone (LS)	8
Carbon (B)	9
Chert (CH)	10

Si litología = 4, 6, 7

AFI = 25

Si litología = 1, 2, 3, 5, 8, 9, 10


AFI = 40

Fuente. Ecopetrol. Instituto Colombiano del Petróleo. ICP

4 PARÁMETROS INFLUYENTES EN LA DETERMINACIÓN DEL ÁNGULO DE FRICCIÓN INTERNA

El ángulo de fricción interna depende principalmente de tres características de la roca como lo son; el deslizamiento entre los granos (que genera fricción debido a la capacidad de las partículas de la roca de deslizarse unas sobre otras), el rodamiento (que son causantes de la generación de fricción debida a la rotación de los granos en la estructura de la roca) y el empaquetamiento (que se encuentra relacionado con la estructura granular) teniendo incidencia directa en la estimación² (ver **Figura 10**).

Figura 10. Parámetros friccionantes de la roca



Fuente. El autor

Basados en estas características, diferentes autores han fundamentado sus investigaciones en relación a las propiedades friccionantes que permiten de manera representativa estimar valores AFI. A continuación son priorizados los parámetros que afectan el comportamiento de las rocas.

² ROZO, A. 2008. Desarrollo de una metodología para determinar el ángulo de fricción interna a partir del volumen de arcilla y la porosidad obtenidos de los registros eléctricos. Proyecto de grado presentado ante la Universidad Industrial de Santander (Bucaramanga, Colombia), como requisito para obtener el título de ingenieros de Petróleos

4.1 COMPACIDAD

Es el principal factor. Cuanto mayor es la compacidad (o menor índice de vacíos), mayor es el esfuerzo necesario para romper la estructura de las partículas y, consecuentemente, mayor el valor de AFI, descrito por Prof. Dr. Pérsio Leister de Almeida Barros³.

4.2 POROSIDAD

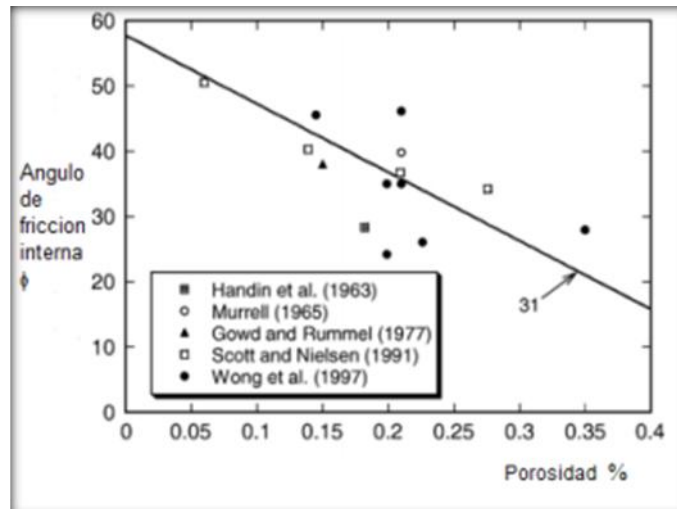
Debido a que la porosidad es consecuencia directa del empaquetamiento de los granos. La porosidad es una de las propiedades petrofísicas más notables que afecta los valores que tome el ángulo de fricción interna.

Frente a este parámetro dos estudios relevantes fueron realizados por: Chandong Chang, Mark D. Zoback Y Abbas Khaksar Y K. Edlmann et al. En el desarrollo de sus investigaciones diseñaron técnicas para la predicción de propiedades mecánicas derivadas de la porosidad obtenidas a partir de registros de pozo. En la determinación de las correlaciones y evaluaciones de tendencia para el diseño de la técnica, muchos pozos fueron documentados y aplicados exitosamente comparados con una extensa gama de muestras de areniscas del Golfo de México en el Mar del Norte, siendo medida cada propiedad mecánica versus la porosidad de la misma.

Su principal aporte representa la relación existente entre la porosidad y el ángulo de fricción interna de la roca describiendo una tendencia lineal inversa, para la cual a mayor porosidad, menor AFI. Ver **Figura 11** y **Figura 12**.

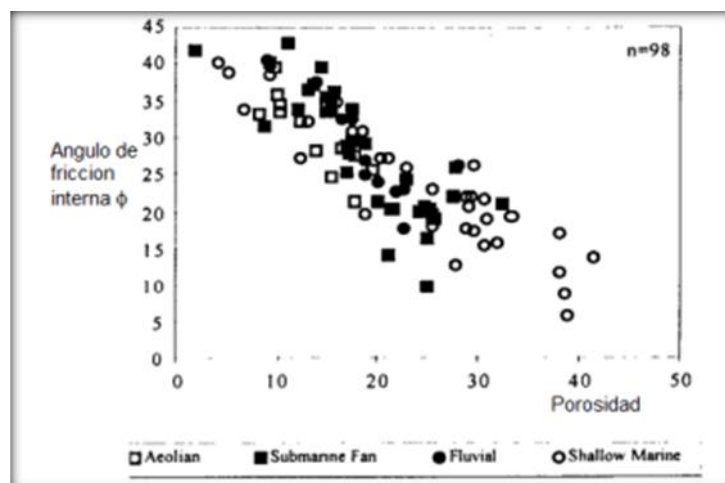
³ PROF. DR. PÉRSIO LEISTER DE ALMEIDA BARROS. Obras de contención manual técnico. MACCAFERRI Maccaferri do Brasil.

Figura 11. Relación entre el ángulo de fricción interna y la porosidad en rocas areniscas en el mar de norte



Fuente. CHANDONG CHANG ET AL. Empirical Relations Between Rock Strength and Physical Properties in Sedimentary Rocks. 2006. JOURNAL OF PETROLEUM SCIENCE AND ENGINEERING

Figura 12. Relación entre el ángulo de fricción interna y la porosidad en rocas areniscas, para diferentes facies marinas



Fuentes. K. EDLMANN, J.M. SOMERVILLE at el. Predicting Rock Mechanical Properties from Wireline Porosities. 1988. SPE.

4.3 GRANULOMETRÍA


En las arenas bien graduadas las partículas menores ocupan los vacíos formados por las partículas mayores, conduciendo a una distribución más estable, con mayor resistencia. Además de eso, las arenas más gruesas

tienden a disponerse naturalmente en forma mas compacta, debido al peso propio de cada partícula. Esto hace que, en general, el valor de AFI sea un poco mayor en las arenas gruesas.

Frente a este parámetro Mostafa Abdou y Abd El-Naiem crearon una forma de medición teniendo en cuenta la distribución del tamaño de grano, con el fin de cuantificar la variación de los valores, debido a la variación de los contenidos de arena y suelo fino, arena media, gruesa o mezclas de algunos o todos de estos tipos, generando ecuaciones empíricas mediante la curva de distribución de tamaño de grano.


Los resultados obtenidos se ven reflejados en el aumento del ángulo de fricción interna al aumentar el tamaño de las partículas de cada tipo de arena (fina, media o gruesa), el aumento al aumentar la densidad de grano y en el caso de baja densidad en seco (cerca del estado suelto) y el aumento al aumentar el porcentaje de arena gruesa (Ver **Figura 13**, **Figura 14** y **Tabla 3**).

Figura 13. Distribución del tamaño de grano de las muestras 1, 2, 3, en donde D es la densidad de grano medida en milímetros y N es el porcentaje de dicho grano contenido en la muestra.



Fuente. ABDU M. Prediction of Angle of Internal of Sand Using Grain-Size Distribution Curve. Assiut University, Egypt.

Figura 14. Distribución del tamaño de grano de las muestras 4, 5, 6, en donde D es la densidad de grano medida en milímetros y N es el porcentaje de dicho grano contenido en la muestra.



Fuente. ABDOU M. Prediction of Angle of Internal of Sand Using Grain-Size Distribution Curve. Assiut University, Egypt.

Tabla 3. Mediciones AFI para diferentes clasificaciones de tamaño de grano relacionadas con la densidad de la mima en gm/cm^3

Specimen	AFI	AFI	AFI
	$\gamma_d=1.5$ (gm/cm^3)	$\gamma_d=1.6$ (gm/cm^3)	$\gamma_d=1.7(\text{gm/cm}^3)$
Sand 1	40.56	43.46	45.85
Sand 2	36.36	40.25	46.60
Sand 3	33.53	37.04	40.24
Sand 4	33.62	38.36	39.62
Sand 5	33.16	38.03	40.24
Sand 6	33.16	39.32	42.89
Sand 7	32.42	39.32	44.00

Fuente. Abdou M. Prediction of Angle of Internal of Sand Using Grain-Size Distribution Curve. Assiut University, Egypt.

4.4 FORMA DE LAS PARTÍCULAS

Las partículas más redondeadas ofrecen menos resistencia que las irregulares, debido a que estas pueden acomodarse granulométricamente de forma tal que


pueden cubrir en su mayoría los espacios vacíos existentes, presentándose en estas últimas un AFI mayor⁴.

4.5 HUMEDAD

La humedad del suelo tiene pequeña influencia en la resistencia de las arenas. Esto se debe al hecho del agua funcionar como un lubricante en los contactos entre las partículas, disminuyendo el valor de AFI. Además de eso, cuando la arena está parcialmente saturada, surgen tensiones capilares entre las partículas, lo que provoca que aparezca una pequeña cohesión, llamada cohesión aparente. Por lo tanto esta cohesión desaparece cuando el suelo está saturado o seco.

Frente a este parámetro Terzaghi Indica que el ángulo de fricción interna de una arena completamente sumergida es de uno o dos grados menor que el valor de AFI para la misma arena a igual cohesión, pero en un estado completamente seco y Américo Hossne G., J Christopher et al. en sus estudios encontraron como se muestra en la Figura las líneas de nivel con una tendencia hacia la humedad máxima indicando que al aumentar la humedad disminuye el ángulo de fricción interna y por lo tanto la resistencia de la roca (Ver **Figura 15**).

Figura 15. Resistencia al corte versus la humedad y el ángulo de fricción interno para un suelo Utisol de sabana franco arenoso del estado de Monagas



Fuente. Hossne A. Resistencia Terramecánica en Función de la Humedad Edáfica de un Suelo Ultisol de Sabana del Estado Monagas, Venezuela. Bioagro. 2003.

⁴ PROF. DR. PÉRSIO LEISTER DE ALMEIDA BARROS. Obras de contención manual técnico. MACCAFERRI Maccaferri do Brasil

4.6 ANISOTROPÍA

Mientras el criterio de falla para rocas intactas asume que la masa de roca se comporta como un material isotrópico, realmente la mayoría de las rocas experimentan una dirección experimental de falla y son llamadas rocas anisotrópicas. En el caso de rocas sedimentarias, las variaciones mineralógicas a través de los granos en diferentes capas y otros rasgos deposicionales tales como planos de buzamiento, foliación o zonas y esquistosidad pueden causar anisotropía.

La anisotropía incide en propiedades tales como la resistencia (tensión, compresión y corte), propiedades de deformación y tasas de filtración, como lo estableció Ramamurthy en 1993⁵. Existen dos tipos de anisotropía; inherente e inducida. La anisotropía inherente es causada durante la formación de la roca (planos de buzamiento, foliación) y la anisotropía inducida es causada por cambios en los esfuerzos después de que la roca es formada (conexiones, fracturas, planos de corte y fallas).

Ramamurthy, clasificó la anisotropía en tres tipos:

1. Anisotropía tipo U.
2. Anisotropía tipo hombro.
3. Anisotropía de tipo ondulatoria.

La anisotropía tipo en U es generalmente vista en pizarras las cuales tiene un set paralelo de clivaje o plano de debilidad como una fuente de anisotropía. La anisotropía tipo hombro es observada en materiales tales como la arenisca debido a su depositación natural y la anisotropía tipo ondulada es observada en carbones, diatomitas y los modelos de pared de ladrillos (brick wall) donde la presencia de varios planos de debilidad pueden ser visto uno a través de otro.

⁵ Chen, X. C.P Tan and C.M Haberfield "Wellbore Stability Analysis Guidelines for Practical Well Design" SPE 20058 1996

Camacho Javier, Reyes Oscar y Nieto Andrés⁶, desarrollaron ensayos de laboratorio para estudiar de qué forma se pueden relacionar las condiciones de anisotropía inducida por esfuerzos, sobre los parámetros de resistencia de arenas. Se utilizó arena limpia y se controló cuidadosamente la distribución granulométrica y la densidad relativa de cada espécimen, el cual se sometió a una combinación preestablecida de esfuerzos bajo condiciones drenadas. Finalmente cada probeta fue llevada a la falla para obtener los parámetros de resistencia al corte.

Los resultados obtenidos muestran variaciones hasta del 10 % en el ángulo de fricción interna, dependiendo de la densidad relativa del material y se observan los efectos negativos especialmente en arenas mal gradadas de densidad relativa media. Demostrándose entonces del estudio que la variación de la anisotropía de las rocas es un parámetro fundamental en la variación del ángulo de fricción interna.

En una serie de pruebas triaxiales, sobre un material dado que contiene una serie de planos de debilidad, es claro que si se escoge el eje de la muestra paralelo a los planos de debilidad no se observará ningún efecto de acuerdo al criterio de Mohr, ya que no existe esfuerzo de cizalladura sobre el plano de debilidad en estos casos. También es claro que para algunas orientaciones intermedias de los planos de debilidad, se espera que haya menos resistencia sobre los planos para esfuerzos bajos, que la resistencia que se espera para la roca intacta. La relación entre la cohesión de los planos de estratificación con la roca intacta es de 0.53 a 1.0 y la relación entre el ángulo de fricción, es de 0.67 a 1.0. De aquí que la diferencia de la resistencia entre la roca intacta y los planos de estratificación debe ser considerada en un análisis de estabilidad de pozo (Chen, X. C.P Tan and C.M Haberfield, 1996).


Analizando este criterio y la aplicación directa para rocas en las cuales se describen planos de debilidad, se plantea el ángulo de ataque como un factor determinante en la estimación AFI, basados en la valoración que refleja la falla

⁶ Camacho Javier, Reyes Oscar y Nieto Andrés. Anisotropía de esfuerzos y resistencia al corte de las arenas. Ciencia e Ingeniería Neogranadina. 2006

a lo largo de los planos de buzamiento mas débiles, mas conocidos como planos de debilidad.

Este ángulo se define como la orientación del pozo con respecto a los planos de buzamiento, en donde dicho ángulo toma un valor de 90 grados cuando el pozo esta perpendicular a las capas, y de 0 grados en el caso de que el pozo este paralelo a los planos de buzamiento (Ver **Figura 16**).

Figura 16. Relación del ángulo de ataque y el plano de debilidad.



Fuente. El autor

Muchos autores han investigado en detalle el comportamiento de las propiedades mecánicas de rocas anisotrópicas (Jaeger 1960, McLamore 1967, Donath 1972, Nova, 1980). Concluyendo de que la máxima resistencia se produce cuando la carga es perpendicular a los planos de anisotropía ($\beta = 90^\circ$), por lo cual un variación generaría resultados bastante variables.

4.7 VOLUMEN DE ARCILLA

El ángulo de fricción interna presenta muy poca variación en las rocas cohesivas, es decir en las arcillas, debido a que estas presentan en su naturaleza cristalina muy pocos de los parámetros que están afectando el AFI. Desde este punto de vista es muy poco probable que el volumen de arcilla afecte significativamente la medida, sin embargo aunque su variación no representa una influencia representativa, para un medio o alto contenido de

arcilla en la roca es considerado como un factor amortiguador de la variación AFI y por ende influenciador en la estimación.

Angélica Rozo. (2006). genero un proyecto en el cual presenta la influencia de la porosidad y el volumen de arcilla teniendo en cuenta los tipos de dicho volumen para dos pozos Colombianos. Las propiedades de la roca se obtuvieron a partir de registros eléctricos permitiendo la generación de curvas continuas para todo el intervalo en el que existe registros, arrojando resultados bastante confiables.

Ecuaciones:

Carbonera C5

$$AFI = -422.28036 - 1514,86737\phi + 190.749267V_{clay} \quad [8]$$

Carbonera C7

$$AFI = 28.32316358 - 50.41537643\phi + 60.14311943V_{clay} \quad [9]$$

Mirador

$$AFI = 63.40809357 - 35.23651139\phi - 51.87972022V_{clay} \quad [10]$$

Cuervo y Barco

$$AFI = 56.50011546 - 5728976395\phi - 11.03575133V_{clay} \quad [11]$$

5 REGISTROS ELÉCTRICOS

Cada una de las propiedades influyentes en la estimación del ángulo de fricción interna de la roca puede ser medida a partir de registros eléctricos, los cuales valoran cada variable de afectación reflejada en la zona de estudio.

Existen diferentes tipos de herramientas, las cuales registran estas características conforme a su principio de función. Los registros comúnmente empleados para dicha labor son: registro de densidad (estimando la compacidad y porosidad de la roca), registro neutrón y registro sísmico (evaluando la porosidad de la roca), registro de potencial espontáneo y registro de rayos gamma (valorando la presencia y volumen de arcilla contenida y la granulometría presente en la roca) y registros de resistividad (que evalúa el contenido de fluido y tipo de roca).

A continuación se describirán los principios de las herramientas anteriormente mencionadas, con el fin de conocer el mecanismo de medición, factores de falla y funcionamiento de cada registro.


5.1 REGISTRO DE DENSIDAD

El Registro de Densidad, mide la densidad aparente de la formación. Su uso principal se encuentra en la determinación de la porosidad total -factor importante en esta investigación-, densidad de los hidrocarburos, evaluación de arenas arcillosas y litologías complejas.

La herramienta consta de una fuente radiactiva, la cual se aplica a la pared del hueco por medio de un patín, que emite rayos Gamma de energía media dentro de la formación (Ver **Figura 17**). La fuente y los detectores están diseñados de manera tal que la respuesta de la herramienta se deba a la dispersión por

efecto Compton. El número de interacciones debidas al efecto Compton se relaciona directamente con la densidad de electrones, y esta a su vez se relaciona con la densidad verdadera de la mayoría de las formaciones sedimentarias (Schlumberger, 1989).

Figura 17. Herramienta y principio de funcionamiento del Registro de Densidad



Fuente. Escamilla R. Modelamiento de Registros Sónico Y Densidad para la Elaboración de Modelos Geomecánicos del Área De Piedemonte. . Proyecto de grado presentado ante la Universidad Industrial de Santander (Bucaramanga, Colombia), como requisito para obtener el título de ingenieros de Petróleos. 2007.

5.2 Cálculo de la porosidad

Como se mencionó el registro de Densidad mide la densidad de electrones, la cual es proporcional a la densidad física de la masa de la formación. La medida básica de la herramienta es la densidad ρ_b medida en g/cm^3 .

$$\rho_b = \phi \rho_f + (1 - \phi) \rho_{ma} \quad [12]$$

La $\rho_b = \phi \rho_f + (1 - \phi) \rho_{ma}$ [12 muestra la relación entre la densidad bulk (ρ_b) y la porosidad de la formación (ϕ), la cual puede ser escrita nuevamente como:

$$\phi = \frac{\rho_{ma} - \rho_b}{\rho_{ma} - \rho_f} \quad [13]$$

Donde ρ_{ma} depende de la litología, ρ_b es medido por el perfil y ρ_f depende del tipo de fluido que ocupa el volumen poroso (filtrado del lodo de perforación).

Los valores típicos de ρ_{ma} para las principales litologías se observan en la **Tabla 4** y los valores de ρ_f se observan en la **Tabla 5**.

Tabla 4. Densidad promedio de una unidad de formación (principales litologías).

Tipo de Roca	Densidad de Matriz (g/cm ³)
Arena	2.65
Limolita	2.71
Dolomita	2.87
Anhidrita	2.98

Tabla 5. Densidad promedio del fluido de perforación (filtrado de lodo).

Base del Lodo	P_f (g/cm ³)
Aceite	0.9
Agua fresca	1
Agua salada	1.1

En rocas densas como areniscas y calizas (cuantías altas de la curva de Densidad, RHOB) mostrara entonces altas porosidades y bajas compactaciones para lo cual se presenta inestabilidad con valores bajos de AFI.

5.3 FACTORES QUE AFECTAN EL PERFIL

Aunque los registros eléctricos presentan grandes ventajas, especialmente para aplicaciones normalmente complejas, existen algunos factores que afectan la medida que hay que tener en cuenta en el momento de la interpretación. Algunos de ellos son:

- ◆ Litología

Es necesario conocer la ρ_{ma} correcta para obtener la porosidad correcta.

- ◆ Estado de hueco

La profundidad de investigación de la herramienta hace que sea sensible a la calidad del pozo, por lo que es necesario interpretar la densidad de la formación de registro junto con el registro Caliper para asegurar que los valores medidos no es un artefacto de la calidad de un mal agujero.

- ◆ Efecto de la presión de compactación

En zonas donde existe una sobrepresión la densidad de la lutita decrece con el incremento de la profundidad (densidades menores a las que corresponde), por lo tanto se pueden utilizar perfiles de densidad corridos de techo en techo durante la perforación para predecir la presencia de zonas sobresaturadas.

- ◆ Efecto de los hidrocarburos

El residuo del petróleo hará la lectura de la densidad de porosidades sea un poco más alta porque el petróleo es más liviano que el filtrado del lodo de perforación, por lo que su presencia es de gran importancia en el momento de la interpretación.

- ◆ Efecto de las Lutitas.

La densidad de las lutitas tiende a ser menor en profundidades pequeñas donde la fuerza de compactación no es tan grande.

Las lutitas dispersas en los espacios porosos pueden tener en general, densidades menores que las lutitas intercaladas.


5.4 REGISTRO NEUTRÓN

El registro neutrón es usado principalmente para ubicar formaciones porosas y determinar su porosidad, propiedad importante para el cálculo del ángulo de fricción interna de la roca. Dicho perfil responde a la cantidad de hidrogeno presente en la formación, por lo cual en formaciones limpias cuyos poros están llenos de agua o petróleo, el registro neutrón indica un valor real en el espacio poroso saturado de fluido.

La medición de los parámetros que determina el registro neutrón se realiza colocando una fuente radiactiva en el centro del pozo que emite continuamente neutrones a la formación comúnmente de 2MeV. Los electrones emitidos colisionan con los núcleos de los átomos que se encuentran en la formación. Con cada colisión del neutrón de la fuente con la formación, hace que se presente una pérdida de energía la cual depende de la masa entre los núcleos (choque elástico). A medida que colisionan en pocos microsegundos, los neutrones son frenados debido a las sucesivas colisiones hasta alcanzar velocidades térmicas, alrededor de 0.025Me V.


La **Figura 18** evidencia que como resultado del choque y pérdida de energía, los neutrones se esparcen aleatoriamente siendo capturados por átomos como Cloro, Hidrógeno o Silicio. La captura de los neutrones, produce una excitación liberando un rayo gamma y retornando a su nivel de energía natural (choque inelástico) denominados rayos de captura (Ver **Figura 19**) los cuales son registrados por una sonda ubicada en medio del pozo.

Figura 18. Esquema de visualización de la interacción entre los neutrones generados por la herramienta neutrón.



Fuente. Modificado de R, Pemper et al 2006. A new pulsed neutron sonde for derivation of formation lithology and mineralogy. SPE 102770.

Figura 19. Herramienta CNL de dos detectores (uno lejano y otro cerca a la fuente).



Fuente. . Mantilla, A y Bueno R. Seminario de Petrofísica e interpretación de Registros de Pozos. Instituto Colombiano del Petróleo- ECOPETROL. Octubre de 2006

Los parámetros registrados son las “cuentas por segundo” de ambos detectores, de los cuales se calcula la relación entre ellos NRAT (Thermal Neutron Near Far Ratio), dividiendo las cuentas por segundo del detector cercano por las del lejano y ya que la emisión del rayo Gamma depende principalmente de la disminución de la velocidad del neutrón causado por el choque con átomos de igual tamaño, hace que la disminución de la velocidad dependa de la cantidad de hidrógeno presente en la formación.

5.4.1 Determinación de la porosidad.

Todo perfil neutrónico puede proporcionar valores de porosidad aparente siempre que se tomen en cuenta algunas correcciones y suposiciones. Efectos como la litología, contenido de arcilla, cantidad y tipo de hidrocarburo determinado por neutrón pueden ser comparados con otros registros como sónico para la determinación de la validez de los resultados.

La porosidad Neutrón de una formación limpia se obtiene como la suma de las porosidades neutrón de cada elemento, ponderada por su volumen en la formación; en el caso de una formación limpia con porosidad y la zona lavada de más de 45 centímetros de extensión, la ecuación de respuestas es:

$$\phi_{NLlog} = \phi \times \phi_{NLmf} + V_{ma} \times \phi_{NLma} \quad [14]$$

Donde:

ϕ_{NLlog} : Índice de hidrogeno de la formación, matriz de caliza. En PU (Porosity Units).

ϕ : Porosidad de la formación, ($0 \leq \phi \leq 1$).

ϕ_{NLmf} : Índice de hidrogeno del filtrado, matriz caliza en PU, ($\phi_{NLmf} \approx 100$ PU).

V_{ma} : Fracción de la roca ocupada por la matriz limpia, ($0 \leq V_{ma} \leq 1$).

ϕ_{NLma} : Índice de hidrogeno de la matriz limpia, matriz caliza en PU, ($-2 \leq \phi_{NLma} \leq 3$).

En la $\mathbf{1} = \emptyset + V_{ma}$
 [15], la suma de la porosidad y el volumen de la matriz constituyen volumen total de la roca, entonces se debe cumplir que:

$$\mathbf{1} = \emptyset + V_{ma} \quad [15]$$

Combinando la $\emptyset_{NLlog} = \emptyset \times \emptyset_{NLmf} + V_{ma} \times \emptyset_{NLma}$
 [14] y $\mathbf{1} = \emptyset + V_{ma}$
 [15] se puede obtener la porosidad aparente para la formación limpia, así:

$$\emptyset_{Na} = \frac{\emptyset_{NLlog} - \emptyset_{NLma}}{\emptyset_{NLmf} - \emptyset_{NLma}} \quad [16]$$

Es interesante observar que cuando la matriz es caliza, el índice de hidrogeno de la matriz limpia es igual a ± 0 PU (Porosity Units), y el valor del índice del filtrado es igual a ± 0 PU, entonces es cuando la porosidad aparente resulta ser igual a la porosidad de la formación, confirmando así, que el registro neutrónico en matriz caliza, obtiene directamente la porosidad en calizas limpias; y ahora la suma de la porosidad con el volumen de la matriz y el volumen de lutita, constituyen el volumen total de la roca, cumpliéndose que:

$$\mathbf{1} = \emptyset + V_{ma} + V_{sh} \quad [17]$$

Donde:

V_{sh} : Valor de la fracción de la roca ocupada por la lutita, ($0 \leq V_{sh} \leq 1$).

Cada compañía de registros tiene consigo un sistema de unidades neutrón: cps (Schulumberger), unidades estándar de neutrones (PGAC), unidades ambientales (Lane Wells), etc. El instituto americano del petróleo (API) estandarizó la unidad en donde 1000 API se definen como la diferencia entre

las lecturas de neutrones en la herramienta con la presencia de fuente y sin esta.

La respuesta que se espera a partir de la curva de NPHI (Curva del registro Neutrón) será que a valores de porosidad altos, estimación de AFI bajos.

5.5 FACTORES QUE AFECTAN EL PERFIL

Como se mencionó con anterioridad, existen algunos factores que deben tenerse en cuenta en el momento de la interpretación de los registros debido a las dificultades que pueden presentarse. A continuación se presentan los más importantes.

- ◆ El efecto de Hidrocarburos.

La presencia de hidrocarburos líquidos, no afecta la respuesta de la herramienta, ya que tiene aproximadamente el mismo índice de hidrógeno como el agua dulce. Sin embargo, los hidrocarburos gaseosos si, debido a que tiene un índice mucho más bajo de hidrocarburos como resultado de su baja densidad, y su presencia dará lugar a subestimaciones de la porosidad.

- ◆ El efecto de las Lutitas.

Las lutitas muchas veces tienen asociado consigo 'ven' que es el agua confinada irreducible. Esto aumenta el índice de hidrógeno de la formación. Incluso lutitas con porosidad muy baja pueden dar lecturas erróneamente, reflejando una alta porosidad debido a la presencia de estas aguas consolidadas.

- ◆ El efecto de cloruro.

El cloro es un buen absorbente de neutrones, y puede conducir a sobreestimaciones de la porosidad si está presente, ya sea como fluido de formación o de filtrado de lodo.


5.6 REGISTRO SÓNICO

El Registro Sónico fue inicialmente desarrollado como un soporte a la interpretación de datos de sísmica, pero se ha convertido en una ayuda de gran importancia en la terminación de la porosidad, fracturas y litología de las formaciones, midiendo el registro sónico el tiempo de transito de una onda elástica cuando esta viaja a través de una formación. Este perfil, al igual que los dos anteriormente mencionados, presenta importancia en la estimación del ángulo de fricción interna, debido a la importancia en la determinación de la porosidad de rocas sedimentarias y a la calibración que puede generarse a partir de él en diferentes registros de pozo.

La propagación del sonido en un pozo es un fenómeno complejo que está regido por las propiedades mecánicas de ambientes acústicos diferentes. Estos incluyen la formación, la columna de fluido del pozo y la misma herramienta del registro.

El sonido emitido por el transmisor choca contra las paredes del hueco (Ver **Figura 20**). Esto establece ondas de compresión y de cizallamiento dentro de la formación, ondas de superficie a lo largo de la pared del hueco y ondas dirigidas dentro de la columna de fluido.


Figura 20. Herramienta de Registro Sónico



Fuente. Ing. Andrés Mantilla Z y Ricardo Bueno S. Seminario De Petrofísica E interpretación de Registros de Pozos. Octubre de 2006.

La pared y rugosidad del hueco, las capas de la formación, y las fracturas pueden presentar discontinuidades acústicas significativas. Por lo tanto, los fenómenos de refracción, reflexión y conversión de ondas dan lugar a la presencia de muchas ondas acústicas en el hueco cuando se está corriendo un registro sísmico. Teniendo en cuenta estas consideraciones no es extraña que muchas llegadas de energía acústica sean captadas por los receptores de una herramienta de registro sísmico. Las llegadas de energía más comunes se muestra en la **Figura 21** donde se muestran los diferentes tiempos de llegada de las ondas tipo P, S, Rayleigh Y Stoneley.

Figura 21. Tren de ondas recibidas por un registro sonoro



Fuente. Dr. Paul Glover. Petrophysics Course Notes.

Después de algún tiempo el primer tipo de onda llega. Esta es la onda de compresión (ondas P) que por lo general, es más rápida que la onda S y tiene una pequeña amplitud. Este tipo de onda puede viajar a través del lodo y la roca, dependiendo entonces de la litología, porosidad, de los fluidos y la presión efectiva. La segunda onda en llegar es la onda transversal o de corte S la cual es más lenta que la onda P, pero por lo general tiene una mayor amplitud, la cual no se propaga en fluidos, debido a que los líquidos no se comportan de manera elástica a la deformación de corte y dependen de la litología, porosidad y presión efectiva de la formación a evaluar. Y por último llegan las ondas de Rayleigh y las ondas de Stoneley, las cuales se asocian con la energía en movimiento a lo largo de la pared del pozo. Este tipo de

ondas pueden ser de gran amplitud, viajando a través de la interfase lodo – roca, presentando sensibilidad a la permeabilidad y fracturas.

5.7 DETERMINACIÓN DE LA POROSIDAD

Existen herramientas complejas que hacen uso solo de las ondas P para la medición u otras que toman en cuenta las ondas S, y algunas otras que registran el tren de onda completa.

La diferencia entre el tiempo de tránsito del pulso entre el receptor y transmisor ($t_2 - t_1$) corresponde al tiempo que demora el sonido para atravesar una sección de la formación, cuya longitud es igual a la distancia entre los receptores. Dividiendo esa diferencia de tiempo entre estas distancias, se tiene el tiempo que tarda la onda en viajar por un pie de formación (Δt).

En la práctica, los datos de registro sonoro no se presentan como un tiempo de viaje, porque las herramientas tienen espaciamentos diferentes, por lo que sería una ambigüedad. Tampoco se trata de datos que se presentan como una velocidad. Los datos se presentan como el tiempo de viaje por pie, que se llama Δt , y se mide generalmente en $\mu s / \text{pie}$.

En la **Tabla 6** se muestran algunos valores que se registran del DT a partir de las diferentes velocidades y tiempos que de viaje para diferentes tipos de roca:

Tabla 6. Algunos Valores de Δt y V para diferentes tipos de roca.

Material	Δt ($\mu s / \text{ft}$)	V (m/s)
Arena compacta	55.6- 51.3	5490-5950
Calizas	47.6-43.5	6400-7010
Dolomita	43.5-38.5	7010-7920
Anhidrita	50.0	6096
Halita	66.7	4572
Shale	170-60	1790-5805

Material	Δt (μs / ft)	V (m/s)
Carbón bituminoso	140-100	2180-3050

Wyllie propuso en 1956 una relación lineal entre el tiempo de tránsito y la porosidad de la siguiente como se muestra en la

$$\Delta T_{log} = \Delta T_f \phi + \Delta T_{ma}(1 - \phi - V_{s\phi}) + \Delta T_{s\phi} V_{s\phi} \quad [18]$$

$$\Delta T_{log} = \Delta T_f \phi + \Delta T_{ma}(1 - \phi - V_{s\phi}) + \Delta T_{s\phi} V_{s\phi} \quad [18]$$

- ◆ Para arenas impías y consolidadas:

$$\phi_s = \frac{\Delta T_{log} - \Delta T_{ma}}{\Delta T_f - \Delta T_{ma}} \quad [19]$$

- ◆ En carbonatos:

$$\Delta T = A + B(1 - \phi) \quad [20]$$

- ◆ En arenas no compactas:

$$\phi_a = \frac{\Delta T - \Delta T_{ma}}{\Delta T_f - \Delta T_{ma}} \quad [21]$$

Valor corregido aplicando el factor de compactación a partir de la $\phi_c = \frac{\phi_a}{c_p}$
 [22:

$$\phi_c = \frac{\phi_a}{c_p} \quad [22]$$

Para lo anterior puede definirse entonces que a mayor tiempo de transito de la onda P (onda de medida utilizada para el registro sísmico), menor porosidad de

la roca y menor compacidad de la misma para lo cual mayores valores de AFI se esperan.

5.8 FACTORES QUE INFLUYEN EN LA MEDICIÓN

Esta herramienta, presenta 3 factores que en gran medida pueden llegar a afectar la estimación que se genere. A continuación se nombraran cada uno, con el fin de que puedan ser analizados en el momento de la interpretación de los datos.

- ◆ La matriz.

La velocidad del sonido en la formación depende del tipo de mineral que constituye la roca. El efecto de los minerales es determinado por sus respectivas densidades y parámetros de elasticidad. Estos parámetros no siempre conocidos en su totalidad. En el caso de litologías complejas el efecto del mineral individual es determinado por su fracción de volumen y su velocidad de sonido.

- ◆ La porosidad y el fluido.

La velocidad del sonido depende de la porosidad y de los fluidos del espacio poroso, teniendo en cuenta:

- ◆ Generalmente si para una porosidad y matriz constante se reemplaza agua por aceite o aceite por gas, la velocidad disminuirá al menos hasta una determinada profundidad.
- ◆ La velocidad del sonido en el agua depende de la salinidad, de tal forma que ha mayor salinidad se tendrá una mayor velocidad.

- ◆ Textura.

La forma en la cual los granos y la porosidad de una formación están arreglados tiene igualmente una influencia en la velocidad del sonido, por lo cual un gran cambio o variación en los mismos puede generar malas medidas.

5.9 REGISTRO RAYOS GAMA

El registro de Rayos Gamma mide el total de radiación gamma natural que emana de una formación. Este detecta y evalúa minerales radiactivos que en su mayoría pertenecen a tres series diferentes; Uranio-Radio, Uranio-Actinio y Uranio-Torio. La radiactividad natural de las rocas se determina por la cantidad de elementos radiactivos que contienen las cuales se encuentran relacionadas a su vez con la composición química de las rocas, así como sus características litológicas y petrográficas, siendo entonces una herramienta que refleja el contenido de arcilla o lutita de las rocas sedimentarias y puede llegar a identificar también el tamaño de grano presente en la roca, debido a que los elementos radiactivos que tienden a concentrarse en este tipo de rocas.

El contenido de arcilla fue determinado con anterioridad como factor amortiguador para la estimación del ángulo de fricción interna además de la granulometría, por lo cual es importante conocer la evaluación generada en el momento de la medición y afectación del mismo, para lo cual a mayores valores de GR, valores bajos de AFI .


5.9.1 Principio de medición.

En su paso por la formación los rayos gamma pierden energía por las colisiones, fenómeno denominado efecto Compton, y son absorbidos por los átomos de la formación liberando electrones, fenómeno denominado efecto fotoeléctrico. El grado de absorción varía con la densidad de la formación. De dos formaciones con la misma cantidad de material radiactivo por unidad de volumen, pero de diferente densidad, la menos densa se mostrara como más radiactiva en el perfil de Rayos Gamma (Si es bastante baja, es posible hacer una clara distinción entre areniscas –baja radiactividad- y lutitas –mayor radiactividad-).

5.9.2 Equipo.

El equipo utilizado está diseñado con una sonda en la cual se encuentra el detector de la radiación gamma, un receptor al cual llegan las radiaciones, una fuente de alta tensión (que alimenta los contadores de radiación), un amplificador de pulsos que se producen cuando un fotón gamma llega a él y los amplifica para que suban a la superficie por medio de cables y por último pasan a unos paneles en la superficie que analizan la amplitud, empleando las mediciones espectrales que se presentan de las variaciones de la densidad de rocas que componen el corte del pozo. El punto de referencia de la medición es el punto medio entre la sonda y el detector (Ver **Figura 22**).

Figura 22. Esquema de funcionamiento de un equipo de Rayos Gamma



Fuente. EARL, D Pile E.K. 2002. Well Logging in Nontechnical Language. BSME University of Tennessee.

5.9.3 Usos del Perfil de Rayos Gamma.

Entre los usos más reconocidos del registro de Rayos Gamma se encuentra:

- ◆ Cálculo de la litología.

El perfil de Rayos Gamma supone la potencia del material radiactivo expresada en flujo de rayos gamma por grano constante. También supone que las variaciones de densidad son debidas a cambios en la porosidad, cambios litológicos ordinarios y no a la presencia de elementos de número atómico elevado que podrían cambiar las características de absorción.

La medición de la cantidad de arcilla que contiene un tipo de roca se ve reflejada siguiendo la siguiente ecuación:

$$GR = \frac{\rho_1 v_1}{\rho_b} A_1 \quad [23]$$

Donde:

GR: Cantidad de mineral radiactivo

ρ_1 : densidad del mineral radiactivo.

V1: fracción de volumen total del mineral

$\frac{\rho_1 v_1}{\rho_b}$: Concentración en peso del material radiactivo.

A1: radiactividad de mineral.

Y cuando este posee más de un mineral radiactivo se suman las diferentes Gamas Ray de cada mineral.

La herramienta de Rayos Gamma permite registrar la radiactividad de las rocas existentes en la formación, principalmente la que proviene de los elementos del Torio, Uranio y Potasio, estos elementos están presentes principalmente en las arcillas por lo que cuando la herramienta se corre en formaciones con alta presencia de arcillas los valores que arroja (en unidades API) el GR es alto; y por ende al arrojar valores bajos se interpreta que la formación es una arena, ya que estas presentan cantidades insignificantes de material radiactivo.

◆ **Calculo del volumen de arcilla**

Para calcular el volumen de arcilla a partir de un registro de Rayos Gamma se han planteado diversas fórmulas, cada una con su rango o características de aplicación, entre estas se tiene la ecuación del índice

de arcilla que es una de las más usadas por su sencillez y su amplio rango de aplicación:

$$V_{sh} = \frac{GR_o - GR_{clear}}{GR_{sh} - GR_{clear}} \quad [24]$$

Donde:

V_{sh} = volumen de arcilla

GR_o = lectura de GR a la profundidad deseada.

GR_{clear} = lectura significativa del valor más bajo registrada por la herramienta (constante).

GR_{sh} = lectura significativa del valor más alto registrada por la herramienta (constante).

◆ **Calculo de la Granulometría.**

El cuarzo, componente principal de la arena gruesa, no muestra radiactividad, por lo cual y en consecuencia las areniscas describen valores bajos de rayos gamma. Sin embargo las arenas de grano fino se encuentran asociadas a minerales detríticos radiactivos. Los más comunes son los: feldespáticos, mica, minerales pesados y fragmentos líticos. Los dos primeros grupos contienen potasio y torio y los demás solo son contenidos en los shale. Entonces las areniscas de minerales finos causan un alto pico en el valor de rayos gamma, en identificación del tamaño de grano, lográndose identificar la granulometría presente en la formación de estudio.

5.9.4 Profundidad de investigación.

Para los valores promedio del lodo de perforación, podemos decir que la profundidad de la investigación, si se define el 75% de la señal, es de 30 cm.

Tenga en cuenta que la zona de sensibilidad es casi hemisférico, por lo que la profundidad de 30 cm de investigación se aplica tanto en sentido horizontal (perpendicular a la pared del pozo) y sub-vertical (sub-paralela a la pared del pozo). Esto tiene implicaciones para la resolución vertical de la herramienta.

5.9.5 Factores que Afectan la Medida.

Entre los factores que afectan la medida del registro se encuentra las variaciones estadísticas. Dada la naturaleza estadística del fenómeno el número de Rayos Gamma que llega al contador fluctúa incluso cuando la sonda está inmóvil en el pozo, sin embargo, el número de Rayos Gamma contados en un periodo de tiempo relativamente largo será prácticamente constante. Entre otros factores se tiene el espesor de la columna de cemento, el espesor de la tubería de revestimiento, el espesor de la columna de lodo y la excentricidad de la sonda; para hacer las correcciones necesarias por los cambios que pueden sufrir las deflexiones de la curva del perfil por este tipo de factores se encuentra una serie de ecuaciones, algunas en gráficas, que se puede utilizar para hacer las correcciones ya sea manual o a través de programas existentes en la industria.

5.10 REGISTRO CORE GAMMA

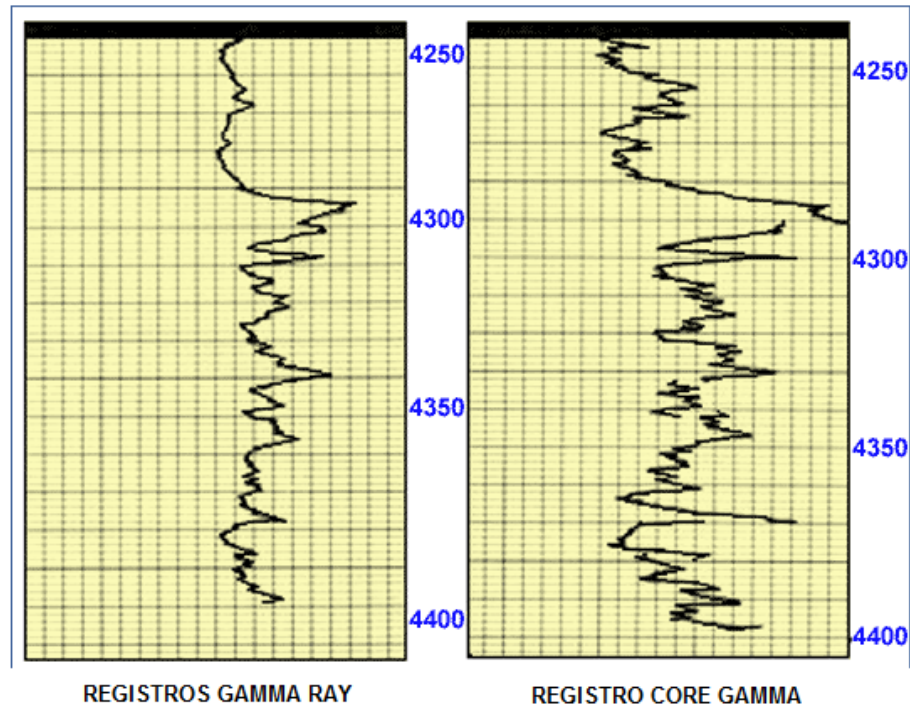
El equipo Spectral Core Gamma se utiliza para determinar la concentración de varios isótopos radioactivos en una muestra de roca. Típicamente se miden las concentraciones de Uranio, Torio, potasio y la radiación total directamente de una muestra de roca. La salida gráfica permite comparar y correlacionar el núcleo de roca con los registros del pozo, identificando zonas de interés y distribución de las zonas arcillosas (Ver **Figura 23**).

El núcleo de rayos gamma registrado queda grabado a la misma profundidad vertical de tal forma que el registro de pozo y el registro Core Gamma puedan ser sobrepuestos. La cantidad de radiación gamma desde el núcleo es proporcional a la medida en el pozo por el registro, aunque no es el mismo debido a la diferencia en la masa del núcleo y la de la tierra que rodea el pozo.

Los factores anteriormente descritos, hacen ver la importancia del registro espectral en la corrección del registro Core gamma con los datos de laboratorio

para los cuales fueron medidas las propiedades en los corazones. Aunque no mide una propiedad directa para la variación AFI, será tenido en cuenta para poder calibrar los datos a utilizar en el entrenamiento de las redes.

Figura 23. Correlación del registro de Rayos Gamma con el registro Core-Gamma) muestra la correlación entre un fondo de pozo y Core-Gamma registro de superficie.



Fuente. <http://translate.google.com.co/translate?hl=es&langpair=en|es&u=http://ipims.com/data/fe32/E3055.asp%3FUserID%3D%26Code%3D3249>

5.10.1 Herramienta

Una banda transportadora lleva la roca a través de un túnel de plomo que reduce el nivel de radiación ambiental y por encima de un detector que produce una señal de salida cuando los rayos gamma inciden sobre él, la salida amplificada se alimenta después en un canal analizador que filtra la señal y elimina los pulsos por fuera de los límites especificados de energía, la salida va a un analizador multicanal (MCA). El MCA puede ser una tarjeta PCI integrada dentro de un PC o un módulo independiente conectado a un PC, El MCA unido

a un PC forma una completa estación de trabajo para espectroscopia capaz de la adquisición y análisis de alta calidad (Ver **Figura 24**).

Figura 24. Equipo Spectral Core Gamma de Corex



Fuente. <http://www.gincor.co/es/core-gama-espectral.html>

Los datos se registran en forma de cuadro para la comparación con la evaluación visual de la litología principal, y de la correlación de profundidad con el registro del fondo del pozo, mediante la alineación de los picos y valles del perfil de gamma medido.

5.11 REGISTRO DE POTENCIAL ESPONTANEO

El registro SP, es un método geofísico y electromagnético directo, el cual mide propiedades como el potencial electroquímico y electrocinético de las rocas descubierto por Schlumberger en 1928. La curva SP muestra potenciales naturales del pozo en función de la profundidad, la cual es determinada por la diferencia de potencial existente entre dos electrodos; un electrodo móvil en el pozo y un electrodo fijo en superficie.

La medición del potencial en el pozo se genera por la corriente espontanea que se presenta debido al contenido de agua almacenada en las formaciones, en los espacios vacios de las rocas porosas y el lodo de perforación, los cuales contienen componentes salinos, y es el movimiento de los iones de estas sales

los que generan una corriente eléctrica que es detectada por medio del electrodo móvil.

Las corrientes son fenómenos naturales y durante el paso al pozo causan cambio en el nivel del potencial eléctrico del lodo. Este potencial varía usualmente de formación en formación y es medido en milivoltios (mv).

En presencia de lutitas, la curva SP define una línea más o menos recta en el registro, línea llamada base de lutitas. En frente de formaciones permeables, la línea muestra deflexiones con respecto a esta línea base; en las capas gruesas estas deflexiones tienden a alcanzar una deflexión esencialmente constante, definiendo así una línea de arenas. A partir de estas características es evidente ver el cambio que presentara el AFI a partir de la variación de SP, para lo cual a valores defectivos bajos de la línea base de shale se pueden presentaran valores altos de AFI, debido al contenido poco arcilloso asociado a la lectura del potencial eléctrico de la zona.

5.11.1 Principio de medición.

Hay tres requisitos para la existencia de una corriente SP:

- ◆ Un líquido de la perforación conductor (es decir, un lodo a base de agua).
- ◆ Una diferencia de capas en el lecho poroso y permeable.
- ◆ Una diferencia de salinidad entre el líquido de la perforación y el fluido de formación, que son el filtrado de lodo y el fluido de formación en la mayoría de los casos.

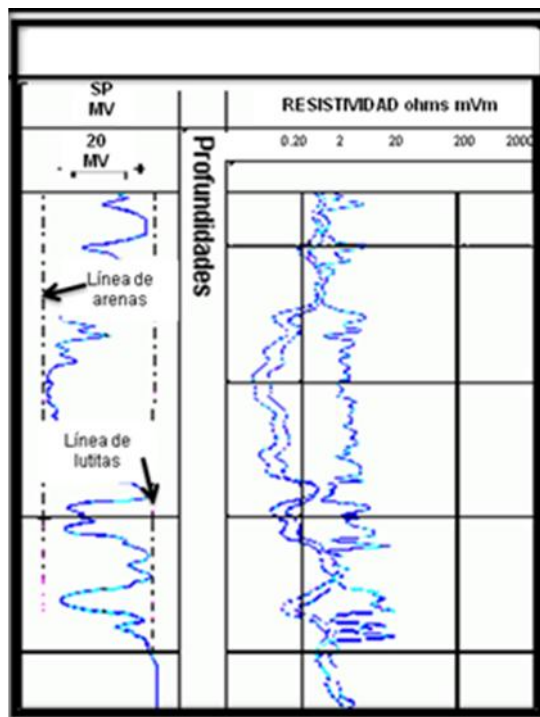
El potencial espontáneo se compone de las contribuciones que se electroquímica (surgen de electricidad interacciones entre los componentes químicos distintos de las rocas y fluidos), y electrocinética (surgen del movimiento de los iones con carga eléctrica en el fluido relativa a la roca fija).

5.11.2 Curva de Potencial Espontaneo (SP).

La curva de potencial espontaneo registra potenciales naturales del pozo en función de la profundidad. Las deflexiones se presentan del flujo de corrientes electricas en el lodo causadas por dos fuerzas electromotrices denominadas componentes electroquímicos y electro cinético del SP las cuales se originan cuando se coloca en contacto la formación con el agua dulce del lodo y el agua contenida en el pozo.

Al presentarse un cambio en la curva se puede ver la diferencia entre las capas permeables y las arcillas. Por ejemplo cuando el electrodo se encuentra en frente de la arcilla se registra una pendiente vertical positiva y se desplaza hacia la derecha del registro. Cuando el electrodo se encuentra en frente de una arena, la curva es de pendiente constante desplazándose hacia la derecha del registro (Ver **Figura 25**).

Figura 25. Método de medición del registro potencial espontaneo.




Fuente. SIERRA, O. 1984. Fundamentals of well-log interpretation. Tomo 1. The acquisition of logging data. Amsterdam.

Los factores que afectan la forma y la amplitud de la curva frente a una zona permeable son el espesor de la capa, resistividad de la capa, diámetro del hueco, profundidad de invasión, contenido de arcillas en zonas permeables y arenas arcillosas petrolíferas.

5.11.3 Equipo.

Esquema del circuito de medición (Ver **Figura 26**). El montaje del equipo consiste en un electrodo en superficie y otro que es movido por medio de un cable (wireline). A medida que se registra la diferencia de potencial por las diferentes formaciones, la información es almacenada en el voltímetro registrador.

Figura 26. Medición del potencial espontaneo a lo largo de un pozo. A) esquema del circuito de medición. B) registro de potencial espontaneo en un pozo con un corte areno arcilloso.



Fuente. SIERRA, O. 1984. Fundamentals of well-log interpretation. Tomo 1. The acquisition of logging data. Amsterdam.

5.12 REGISTROS ELÉCTRICOS RESISTIVOS

La resistividad es una importante pista para la identificación de la litología y el contenido de fluido. El fundamento del método de medición en los registros resistivos es una técnica geofísica que mide la resistividad de cada uno de los estratos, es decir, la resistencia que presenta un material al paso de la corriente eléctrica en la roca.

La importancia de este registro en la estimación del ángulo de fricción interna de la roca, se debe a la identificación de arcillas debido al contenido de fluidos adjunto en dicha roca, los cuales conducen más fácil la corriente eléctrica inducida, para lo cual el AFI disminuirá en altos valores de los registros resistivos.

Los registros resistivos se dividen en: registros eléctricos convencionales, registros enfocados, resistivos, microperfiles y de inducción. Unidades de medición.

En general los registros resistivos, miden como su nombre lo indica la resistividad de la formación en unidades de ohmio-metro con excepción de los perfiles de inducción que miden la conductividad expresada en 1/ohm-metro, considerada como el inverso de la resistividad.

5.12.1 Factores que influyen en la medición.

◆ Arcillas.

Desde que las arcillas tengan agua incorporada, son normalmente buenas conductoras eléctricas y su efecto se suma a la conductividad producida por la solución salina contenida en los espacios porosos, lo cual implica que a mayor arcillosidad, mayor será la conductividad de la roca o menor su resistividad. La arcillosidad de una roca afectará en mayor o menor grado su resistividad dependiendo de:

1. La proporción de arcilla con respecto al volumen de roca.

2. Las propiedades físicas de la arcilla.
3. La manera como la arcilla se ha distribuido en la formación.

◆ **La naturaleza de los fluidos contenidos en los poros.**

La resistividad del agua puede depender de la cantidad de sales disueltas y a mayor cantidad de sales menor resistividad presentara la roca.

En forma contraria el aceite y el gas son malos conductores de la electricidad y cuando estos se introducen en los poros de la roca, el agua que inicialmente se encuentra saturada en la roca es reemplazada por el desplazamiento efectuado por fluidos no conductores.

◆ **Textura de la roca.**

La forma, clasificación y orientación de los granos determina la porosidad, el tamaño de los poros y canales los cuales a su vez influyen en la resistividad en función de la tortuosidad y permeabilidad.

◆ **Temperatura.**

La resistividad varía según la temperatura presente en el fluido, presentándose que a mayor temperatura menor resistividad.

6 INTELIGENCIA ARTIFICIAL

6.1 GENERALIDADES

La inteligencia artificial se define como una ciencia que tiene como objetivo el diseño y construcción de máquinas capaces de imitar el comportamiento inteligente de las personas. Siendo estribada en el uso de la analogía del ordenador no solamente como método de trabajo e investigación sino también de interpretación de la realidad.

Una característica primordial de todo sistema para que se pueda considerar inteligente desde la perspectiva humana, es que sea capaz de comunicarse con las personas en su misma lengua. Un aspecto fundamental a considerar es que la mayor parte de conocimiento humano se codifica en lenguaje natural escrito o hablado, por lo que la comprensión de cómo manejar el lenguaje y como construir programas de ordenador que lo utilicen con la misma habilidad y soltura que los seres humanos es crucial para el avance de la inteligencia artificial.

Uno de los pilares de la inteligencia artificial - IA, es el análisis de cómo los seres humanos resuelven o buscan soluciones a cada uno de los innumerables problemas con los que se encuentran continuamente. Las trayectorias de búsqueda de alguna solución constituyen un capítulo destacado en la construcción de sistemas inteligentes.

Cuando se conoce cuál es la mejor sucesión de acciones necesarias para resolver un problema, se dice que se dispone de un "algoritmo" o procedimiento determinista de resolución. Este es el tipo de situaciones que se abordan en los programas informáticos tradicionales. Por el contrario, los sistemas desarrollados con técnicas de IA deben enfrentarse (al igual que con los seres humanos), con problemas para los que se conoce "a priori" la secuencia exacta de acciones que deben realizarse para encontrar su solución. En consecuencia, esta debe ser determinada mediante una exploración sistemática de alternativas en cada uno de los posibles pasos a dar y, en un

proceso de “prueba-error “más o menos lento, tratar de llegar al objetivo deseado y así encontrar un camino o solución al problema planteado.

Se distinguen varios tipos de procesos válidos para obtener resultados racionales, que determinan el tipo de agente inteligente. De más simples a más complejos, los cinco principales tipos de procesos son⁷:

- ◆ Ejecución de una respuesta predeterminada por cada entrada (análogas a actos reflejos en seres vivos).
- ◆ Búsqueda del estado requerido en el conjunto de los estados producidos por las acciones posibles.
- ◆ Algoritmos genéticos (análogo al proceso de evolución de las cadenas de ADN).
- ◆ Redes neuronales artificiales (análogo al funcionamiento físico del cerebro de animales y humanos).
- ◆ Razonamiento mediante una lógica formal (análogo al pensamiento abstracto humano).

Como solución y ayuda en la aplicación de tecnologías que integren algunas de estas variables de la inteligencia artificial en proyectos aplicativos de soluciones para este caso de variables mecánicas, en el diseño de la metodología AFI, se maneja una herramienta software “ORIONTM” perteneciente al Grupo de Investigación Estabilidad de Pozo, del 2009 diseñada por Laura Galvis y Cesar Ochoa⁸ a partir de un diseño previo, con el fin de adaptar y utilizar trabajos

⁷ Muñoz J. Tutorial de Redes Neuronales Universidad Tecnológica de Pereira, 2000.

⁸ GALVIS, L; Y OCHOA, C. Desarrollo de una herramienta software utilizando redes neuronales artificiales para estimar propiedades del comportamiento mecánico de arenas limpias.

anteriores diseñados por estudiantes en búsqueda de mejoras y aplicaciones de nuevos retos sistemáticos.

La herramienta a utilizar combina dos técnicas de inteligencia artificial, los algoritmos genéticos y las redes neuronales, en creación de un sistema híbrido, donde la primera se aplica para mejorar la segunda. A continuación se explicara el funcionamiento de estas técnicas y la herramienta de aplicación.

7 REDES NEURONALES ARTIFICIALES

Las Redes Neuronales Artificiales (RNA) constituyen una línea de investigación en Inteligencia Artificial (IA), la cual tiene como objetivo primario la construcción de máquinas inteligentes (Grimson y Patil, 1987). La RNA o sistemas conexionistas son sistemas de procesamiento de la información cuya estructura y funcionamiento están inspirados en las redes neuronales biológicas. Consisten en un conjunto de elementos simples de procesamiento llamados nodos o neuronas conectadas entre sí por conexiones que tienen un valor numérico modificable llamado peso.

La actividad que una unidad de procesamiento o neurona artificial realiza en un sistema de este tipo es simple. Normalmente, consiste en sumar los valores de las entradas (inputs) que reciben de otras unidades conectadas a ella, comparar esta cantidad con el valor umbral y, si lo iguala o supera, enviar activación o salida (output) a las unidades a las que esté conectada. Tanto las entradas que la unidad recibe como las salidas que envía dependen a su vez del peso o la fuerza de las conexiones por las cuales se realizan dichas operaciones.

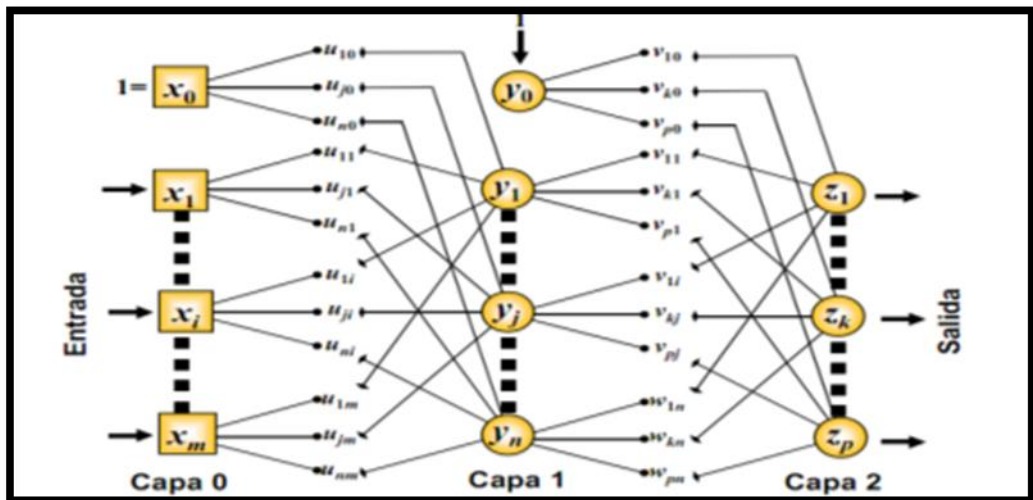
7.1 ARQUITECTURAS DE REDES NEURONALES

Se denomina arquitectura a la topología, estructura o patrón de conexión de una red neuronal. En una RNA los nodos se conectan por medio de sinapsis, esta estructura de conexiones sinápticas determina el comportamiento de la red. En general, las neuronas se suelen agrupar en unidades estructurales que se denominan capas. Finalmente, el conjunto de una o más capas constituye la red neuronal.

Se distinguen tres tipos de capas (Ver **Figura 27**):

- ◆ De entrada: una capa de entrada o sensorial está compuesta por neuronas que reciben datos o señales procedentes del entorno.
- ◆ Oculta: es aquella que no tiene conexión directa con el contorno, es decir, que no se conecta directamente ni a órganos sensores ni a efectores.
- ◆ De salida: es aquella cuyas neuronas proporcionan la respuesta de la red neuronal.

Figura 27. Estructura de una Red Neuronal Artificial



Fuente. Izaurieta F. y Saavedra C., Redes Neuronales Artificiales, Departamento de física, Universidad de Concepción, Chile. 2003.

Las conexiones entre las neuronas pueden ser excitatorias o inhibitorias: un peso sináptico negativo define una conexión inhibitoria, mientras que uno positivo determina una conexión excitatoria.

Las conexiones intra-capas, también denominadas laterales, tiene lugar entre las neuronas pertenecientes a una misma capa, mientras que las conexiones inter-capas se producen entre las neuronas de las diferentes capas. Existen además conexiones realimentadas, que tienen un sentido contrario al de entrada-salida. En algunos casos puede existir realimentación incluso de una neurona consigo misma.

Atendiendo a todos estos conceptos, se puede establecer distintos tipos de arquitecturas neuronales:

- ◆ Redes Monocapa: son aquellas compuestas por una única capa de neuronas.
- ◆ Redes multicapa: son aquella cuyas neuronas se organizan en varias capas.

Atendiendo al flujo de datos en la red neuronal, se puede hablar de:

- ◆ Redes unidireccionales: la información circula en un único sentido desde las neuronas de entrada a las de salida.
- ◆ Redes recurrentes o realimentadas: la información puede circular entre las capas en cualquier sentido.

7.2 REDES NEURONALES Y RECONOCIMIENTO DE PATRONES

El termino de reconocimiento de patrones abarca gran cantidad de problemas y maneja principalmente una vasta área de procesamiento de información, estos problemas son resueltos por los humanos de una manera tan casual que se hace difícil el solo hecho de comprender la complejidad de esta tarea para un computador.

7.2.1 Patrón.

Siguiendo la definición de Watanabe³, un patrón es una entidad a la que se le puede dar un nombre y que está representada por un conjunto de propiedades medidas y las relaciones entre ellas (vector de características). Un patrón entonces puede ser por ejemplo una imagen de una cara en la que el vector de características estaría formado por valores numéricos calculados a partir de la misma.

Gran variedad de disciplinas científicas como la medicina, la biología y la inteligencia artificial tiene entre sus actividades importantes el reconocimiento

automático, descripción, clasificación y agrupamiento de patrones, por lo que es un campo de aplicación de muchas expectativas.

7.2.2 Sistema de reconocimiento de patrones.

Un sistema de reconocimiento de patrones tiene de cualquier manera uno de los siguientes objetivos⁹:

1. Identifica el patrón como miembro de una clase ya definida, es decir una clasificación supervisada.
2. Asigna el patrón a una clase no definida, es decir una clasificación no supervisada, agrupamiento o clustering.

En general, se siguen tres en el diseño de un sistema de reconocimiento de patrones que son:

1. Adquisición y pre proceso de datos.
2. Extracción de características.
3. Toma de decisiones, agrupamiento o clasificación.

La adquisición trata la forma en que se adquieren los datos y las fuentes de los mismos, por ejemplo una maquina de laboratorio, una cámara en el caso de una imagen, etc. Y, el pre proceso son todos los procedimientos que permite organizar y limpiar de cierta manera los datos, desde un análisis de sensibilidad hasta una sencilla tabulación.

En la extracción de características se enumeran las propiedades de vector de características del sistema, esto, mediante un análisis profundo de los patrones para determinar exactamente cuáles son las mediciones cruciales en la identificación de las diferentes categorías bajo investigación. Finalmente, en la etapa de clasificación se determina el tipo de aprendizaje o entrenamiento.

⁹ S. WATANABE. Pattern Recognition: Human and Mechanical.- Wiley, New York 1985

Dependiendo de la tarea para la cual una red neuronal, se define el mecanismo de aprendizaje que es el método sistemático para encontrar un valor adecuado de los pesos que inicialmente son asignados y van evolucionando a unos valores que lleven a encontrar un estado estable de la red, puede ser de forma supervisada o no supervisada.

7.2.3 Aprendizaje supervisado.

Se presenta a la red un conjunto de patrones de entrada junto con la salida esperada. Los pesos se van modificando de manera proporcional al error que se produce entre la salida real de la red y la salida esperada, minimizando el error de la salida calculada. Este tipo de aprendizaje es el utilizado en problemas que implican reconocimiento de patrones y dado que el problema que se trata en este proyecto es de este tipo, el aprendizaje supervisado será la manera como este se maneje.

7.2.4 Aprendizaje no supervisado.

Se presenta a la red un conjunto de patrones de entrada. No hay información disponible sobre la salida esperada. El proceso de entrenamiento en este caso deberá ajustar sus pesos en base a la correlación existente entre los datos de entrada.

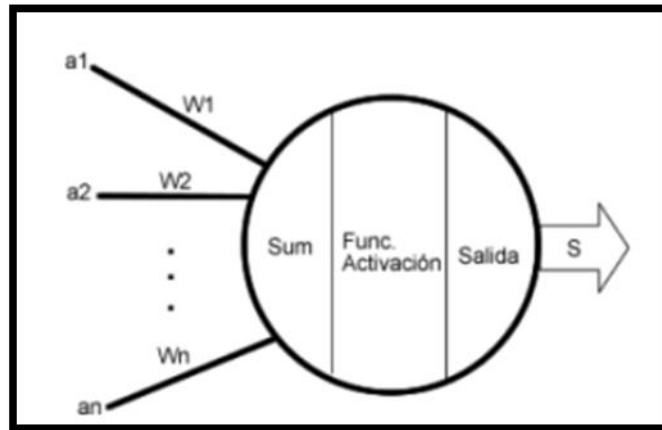
En cualquiera de los casos, la red aprende mediante los ejemplos, pero la importancia radica en la capacidad de generalización, que es la calidad de una salida ante una entrada que no ha sido utilizada en el entrenamiento, así, entonces se diferencian dos fases de funcionamiento, entrenamiento y reconocimiento; en el entrenamiento se fijan los pesos y en el reconocimiento se procesan entradas correspondientes a la aplicación real.

7.3 UNIDADES EN REDES NEURONALES

Como se había expuesto anteriormente, las redes neuronales están compuestas por nodos y uniones entre estos, cada nodo se convertiría en la presentación de una neurona. Y el procedimiento que se desarrolla dentro de

estos consiste en sumatorias de unos valores y la respectiva salida de una función de activación. La **Figura 28** representa un nodo:

Figura 28. Estructura de un nodo en una red neuronal.



Fuente. Mendez. E., y Mariño. J. Sistema Automático de entrenamiento de Redes Neuronales Artificiales Basados en el Ajuste Genético de Parámetros y Variación de Arquitectura. Proyecto de grado presentado ante la Universidad Industrial de Santander (Bucaramanga, Colombia), como requisito para obtener el título de ingenieros de Sistemas.2008.

El funcionamiento es el siguiente:

1. Se tienen datos de entrada (a_1, a_2, \dots, a_n), los cuales son multiplicados por unos pesos (W_1, W_2, \dots, W_n) correspondientes a su línea de comunicación con el nodo, estos pesos tiene como significado lógico la importancia que va a tener dicho valor para el nodo.
2. Luego de entrar a los datos multiplicados por sus pesos ($a_1 * W_1, a_2 * W_2, \dots, a_n * W_n$), estos datos son llevados a una sumatoria dentro de la neurona ($\sum a_i * W_i$).
3. El valor de la sumatoria se evalúa en una función de activación, y la salida de esta es llevada a otros nodos o como salida del sistema.

Como conclusión final, el procedimiento realizado por el nodo es el siguiente:

$$S = G) \sum_{i=1}^n (a_i \times W_i) \quad [25]$$

Donde G es la función de activación, a_1 es una de las entradas al nodo y además es multiplicado por su peso W_i , y finalmente S será la salida del nodo.

Existen diferentes formas de hallar los pesos en las conexiones de la red neuronal, entre las más utilizadas se encuentra el algoritmo backpropagation (propagación hacia atrás) para topologías perceptrón evolutiva y simulación reconocida con muy buenos resultados¹⁰.

7.4 ESTRUCTURA DE LAS REDES NEURONALES ARTIFICIALES

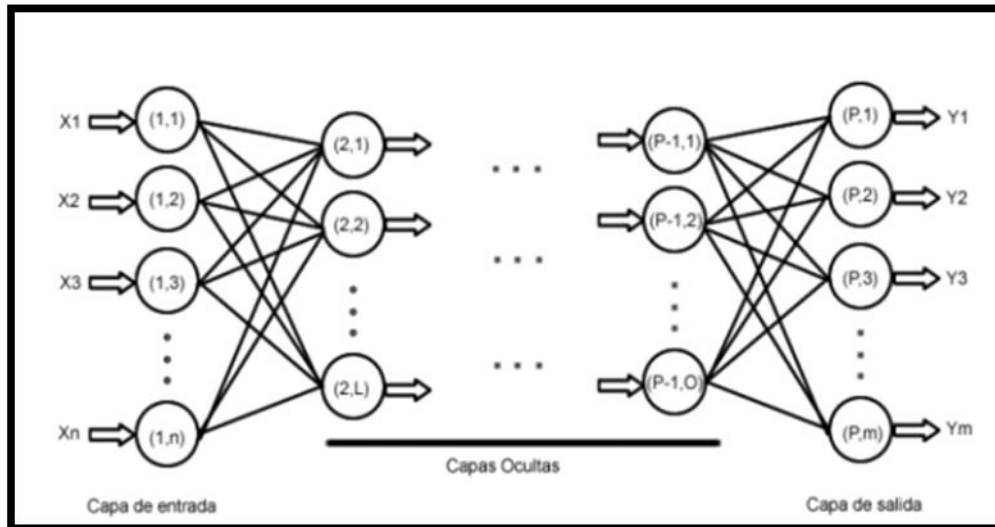
Las categorías de las redes neuronales, se pueden dividir en dos conjuntos, teniendo en cuenta su estructura. Las redes se pueden clasificar en redes acíclicas o redes con alimentación hacia adelante (conocida también como perceptrón) y redes con retroalimentación hacia adelante los datos siguen un flujo directo a la salida, la comunicación entre los nodos de las capas adyacentes.

Las características de las redes cíclicas se encuentra en que los estados actuales de la red supeditados a las salidas dadas con anterioridad por el sistema, en cada salida del sistema uno o varios datos son devueltos como entrada nuevamente de la red. De esta forma, ocurre una retroalimentación que producirá una memoria a corto plazo.

En las redes neuronales con alimentación hacia adelante, también conocidas como perceptrones (simples si se cuenta con una sola capa oculta y multicapa si cuenta con varias capas ocultas), se puede encontrar la siguiente estructura general, ver **Figura 29**.

¹⁰ V.W. Porto, D.B. Fogel, and L.J. Fogel. Alternative Neural Network Training Methods, IEEE EXPERT, 1995.

Figura 29. Estructura del perceptrón multicapa.



Fuente. Mendez. E., y Mariño. J. Sistema Automático de entrenamiento de Redes Neuronales Artificiales Basados en el Ajuste Genético de Parámetros y Variación de Arquitectura. Proyecto de grado presentado ante la Universidad Industrial de Santander (Bucaramanga, Colombia), como requisito para obtener el título de ingenieros de Sistemas.2008.

Los datos que entran a la red tiene que ser normalizados para que puedan ser evaluados en las funciones de activación; la normalización depende las características de estas funciones.

Teniendo en cuenta las estructuras tanto del nodo, como de la red neuronal, se podría hacer una formula general sobre las salidas esperadas de cada nodo. La fórmula que se desarrollaba casa nodo es la siguiente (adicionando en esta ocasión subíndices para indicar un nodo en la estructura de red).

$$S_{i,j} = G_{i,j}(\sum_{k=1}^n a_{i-1,k} \times W_{i,k,j}) \quad [26]$$

$S_{i,j}$: La salida del nodo (i, j)

$G_{i,j}$: Función de activación del nodo (i, j)

$A_{i-1,k}$: Salida del nodo $(i-1,k)$

$W_{i,k,j}$: Peso configurado para la salida del nodo $(i-1,k)$ con destino del nodo (i, j)

Esta ecuación es recursiva, puesto que los valores de entrada a un nodo dependen igualmente de la evaluación de entradas por algún otro nodo de capas anteriores.

7.5 FUNCIONES DE ACTIVACIÓN

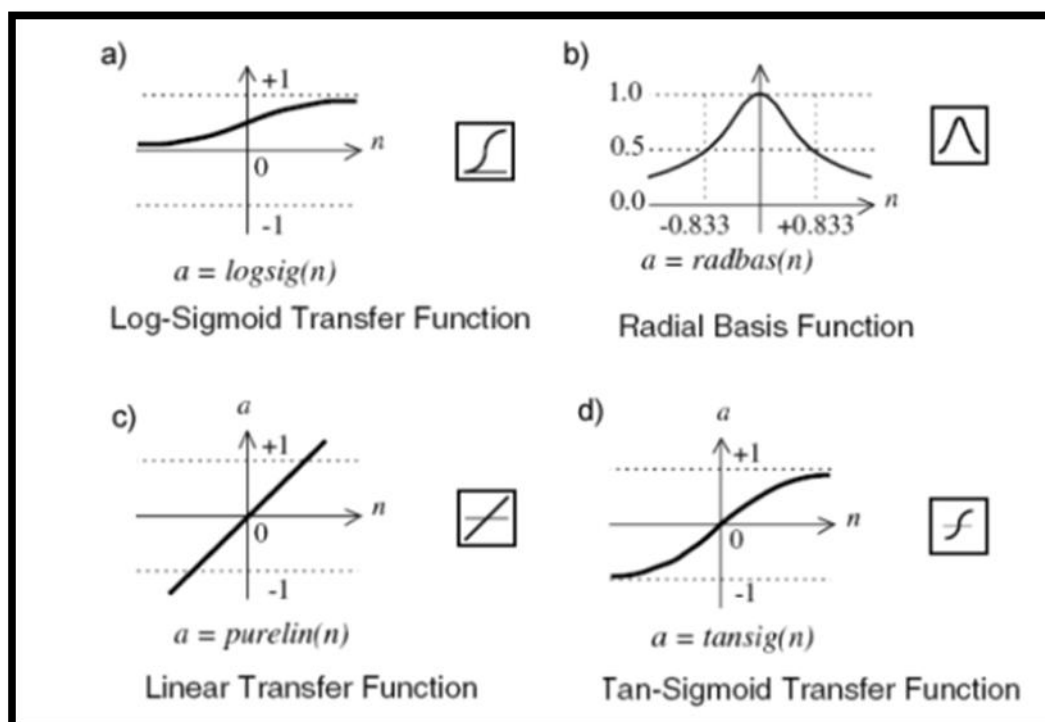
Existen diferentes funciones utilizadas en las redes neuronales artificiales y estudios referentes a las características y aplicaciones en las cuales deben ser aplicadas. En la elección de las funciones de activación (puede ser escogidas diferentes funciones en una sola red neuronal) deben de tenerse en cuenta la velocidad de entrenamiento y la convergencia en poco ciclos; la función debe ser sencilla, tanto original como su derivada, además debe tener una amplia parte lineal¹¹.

Frecuentemente la función paso es utilizada en problemas de clasificación y la función lineal en distintas redes en la casa de salida. Las funciones de patrones con el fin de restringir el rango de salida. La función logística es usada en problemas de predicción, junto con la función gaussiana.

Las algunas de las funciones de activación utilizadas en la herramienta de estimación son, ver **Figura 30**:

¹¹ L. Llano, A. Hoyos, F. Arias, J. Velásquez. Comparación del Desempeño de Funciones de Activación en Redes Feedforward para Aproximar Funciones de Datos con y sin Ruido, Universidad Nacional de Colombia, Sede Medellín, 2007.

Figura 30. Funciones de activación. A. función logística o log sigmoid. B. Función Gaussiana o Radias Basis. C. Función lineal. D. Función tangente hiperbólica o tansing.



Fuente. H. Demuth, M. Beale, M. Hagan. Neural Network Toolbox™ User's Guide, Math Works, inc. 2008, pags 471-474.

7.6 ENTRENAMIENTO DE LAS REDES NEURONALES ARTIFICIALES

El entrenamiento de una red neuronal artificial consiste en, una vez configurada la estructura, ajustar los pesos de las conexiones entre las neuronas o nodos. Mientras se van ajustando estos pesos, se dice que la red está ganando conocimiento, mejorando su capacidad de predicción y/o de clasificación.

Existen diferentes métodos para encontrar el valor de los pesos entre los nodos. Hay entrenamiento evolutivo, basadas en las teorías de evolución biológica, utilizadas para encontrar mínimos globales en espacio muestrales de gran tamaño. La simulación más reconocida es la propagación hacia atrás, basado en técnicas de propagación lineal, entre otros.

7.6.1 Algoritmo de propagación hacia atrás (Backpropagation).

La propagación hacia atrás consiste en minimizar un error (comúnmente cuadrático) por medio de descenso de gradiente, por lo que la parte esencial del algoritmo es cálculo de las derivadas parciales de dicho error con respecto a los parámetros de la red neuronal.

El sistema de entrenamiento mediante back-propagation consiste en:

- ◆ Empezar con unos pesos sinápticos cualquiera (generalmente elegidos al azar).
- ◆ Introducir unos datos de entrada (en la capa de entradas) elegidos al azar entre los datos de entrada que se van a usar para el entrenamiento.
- ◆ Dejar que la red genere un vector de datos de salida (propagación hacia delante).
- ◆ Comparar la salida generada por la red con la salida deseada.
- ◆ La diferencia obtenida entre la salida generada y la deseada (denominada error) se usa para ajustar los pesos sinápticos de las neuronas de la capa de salidas.
- ◆ El error se propaga hacia atrás (back-propagation), hacia la capa de neuronas anterior, y se usa para ajustar los pesos sinápticos en esta capa.
- ◆ Se continua propagando el error hacia atrás y ajustando los pesos hasta que se alcance la capa de entradas.

Este proceso se repetirá con los diferentes datos de entrenamiento.

7.6.2 Propagación hacia atrás con variación en la tasa de aprendizaje.

Una forma sencilla de obtener un aumento en la velocidad de convergencia del de propagación hacia atrás (backpropagation), consiste en ir configurando la rata de aprendizaje a medida que el algoritmo va trabajando. La razón de esto es que con el gradiente descendiente, si se tiene una rata de aprendizaje muy alto, el algoritmo puede quedarse e un mínimo loca, además que se observara una considerable oscilación.

Si la tasa de aprendizaje es muy pequeña, el algoritmo tardara mucho tiempo en encontrar el mínimo. Esta técnica puede ser utilizada tanto en propagación hacia atrás simple como con gradiente descendiente con momentos.

7.6.3 Propagación hacia atrás resilient (Rprop).

Las funciones comúnmente utilizadas de activación en las redes neuronales artificiales, tiene como característica que acepta valores de entrada infinitos en la función (y su salida finita); esto representa un problema cuando se realiza el gradiente de la función. El gradiente tiene magnitudes muy pequeñas, causando pequeños cambios en los pesos y conexiones; aun cuando se encuentra lejos del punto optimo.

El algoritmo Rprop tiene como propósito mejorar el comportamiento indeseado del gradiente (derivadas parciales). Solo es necesaria la dirección de la derivada para poder actualizar los pesos; la magnitud de la derivada no tiene efecto. El cambio realizado en los pesos se halla con otros parámetros por separado.

7.6.4 Algoritmo Quasi-Newton.

Una de las variaciones al algoritmo de propagación hacia atrás consiste en utilizar el método de Quasi Newton, en vez de gradiente conjugado para optimizar la convergencia. Este algoritmo es más rápido que el gradiente conjugado. Pero requiere de mucha capacidad de cómputo para manejar la matriz Hessiana.

7.6.5 Algoritmo Levenberg-Marquardt.

Este algoritmo no necesita hallar matrices Hessianas; algo que aumenta la velocidad de convergencia. Cuando el error se halla por mínimos cuadrados.

7.7 VENTAJAS QUE OFRECEN LAS RED NEURONALES

Debido a su constitución y a sus fundamentos, las redes neuronales artificiales presentan un gran número de características semejantes a las del cerebro. Por ejemplo, son capaces de aprender de la experiencia, de generalizar de casos anteriores a nuevos casos, de abstraer características esenciales a partir de entradas que representan información irrelevante, etc. Esto hace que ofrezcan numerosas ventajas y que este tipo de tecnología se esté aplicando en múltiples áreas. Entre las ventajas se incluyen¹²:

- ◆ Aprendizaje Adaptativo. Capacidad de aprender a realizar tareas basadas en un entrenamiento o en una experiencia inicial.
- ◆ Auto-organización. Una red neuronal puede crear su propia organización o representación de la información que recibe mediante una etapa de aprendizaje.
- ◆ Tolerancia a fallos. La destrucción parcial de una red conduce a una degradación de su estructura; sin embargo, algunas capacidades de la red se pueden retener, incluso sufriendo un gran daño.
- ◆ Operación en tiempo real. Los cálculos neuronales pueden ser realizados en paralelo; para esto se diseñan y fabrican máquinas con hardware especial para obtener esta capacidad.
- ◆ Fácil inserción dentro de la tecnología existente. Se pueden obtener chips especializados para redes neuronales que mejoran su capacidad en ciertas tareas. Ello facilitará la integración modular en los sistemas existentes.

¹² LARRAÑAGA, Pedro; INZA Iñaki y MOUJAHID Abdelmalik. Redes Neuronales. Departamento de Ciencias de la Computación Inteligente e Inteligencia Artificial. Universidad del País Vasco-Euskal Herriko Unibertsitatea,2000

7.7.1 Aprendizaje Adaptativo.

La capacidad de aprendizaje adaptativo es una de las características más atractivas de redes neuronales. Esto es, aprenden a llevar a cabo ciertas tareas mediante un entrenamiento con ejemplos ilustrativos.

Como las redes neuronales pueden aprender a diferenciar patrones mediante ejemplos y entrenamientos, no es necesario elaborar modelos a priori sin necesidad de especificar funciones de distribución de probabilidad.

Las redes neuronales son sistemas dinámicos autoadaptativos. Son adaptables debido a la capacidad de autoajuste de los elementos procesales (neuronas) que componen el sistema. Son dinámicos, pues son capaces de estar constantemente cambiando para adaptarse a las nuevas condiciones.

En el proceso de aprendizaje, los enlaces ponderados de las neuronas se ajustan de manera que se obtengan ciertos resultados específicos. Una red neuronal no necesita un algoritmo para resolver un problema, ya que ella puede generar su propia distribución de pesos en los enlaces mediante el aprendizaje. También existen redes que continúan aprendiendo a lo largo de su vida, después de completado su período de entrenamiento.

La función del diseñador es únicamente la obtención de la arquitectura apropiada. No es problema del diseñador el cómo la red aprenderá a discriminar. Sin embargo, sí es necesario que desarrolle un buen algoritmo de aprendizaje que le proporcione a la red la capacidad de discriminar, mediante un entrenamiento con patrones.

7.7.2 Auto-organización.

Las redes neuronales emplean su capacidad de aprendizaje adaptativo para auto-organizar la información que reciben durante el aprendizaje y/o la operación. Mientras que el aprendizaje es la modificación de cada elemento procesal, la auto-organización consiste en la modificación de la red neuronal completa para llevar a cabo un objetivo específico.

Cuando las redes neuronales se usan para reconocer ciertas clases de patrones, ellas auto-organizan la información usada. Por ejemplo, la red llamada backpropagation, creará su propia representación característica, mediante la cual puede reconocer ciertos patrones.

Esta auto organización provoca la generalización: facultad de las redes neuronales de responder apropiadamente cuando se les presentan datos o situaciones a las que no había sido expuesta anteriormente. El sistema puede generalizar la entrada para obtener una respuesta. Esta característica es muy importante cuando se tiene que solucionar problemas en los cuales la información de entrada no es muy clara; además permite que el sistema dé una solución, incluso cuando la información de entrada está especificada de forma incompleta.

7.7.3 Tolerancia a fallos.

Las redes neuronales fueron los primeros métodos computacionales con la capacidad inherente de tolerancia a fallos. Comparados con los sistemas computacionales tradicionales, los cuales pierden su funcionalidad cuando sufren un pequeño error de memoria, en las redes neuronales, si se produce un fallo en un número no muy grande de neuronas y aunque el comportamiento del sistema se ve influenciado, no sufre una caída repentina.

Hay dos aspectos distintos respecto a la tolerancia a fallos:

- a) Las redes pueden aprender a reconocer patrones con ruido, distorsionados o incompletos. Esta es una tolerancia a fallos respecto a los datos.
- b) Las redes pueden seguir realizando su función (con cierta degradación) aunque se destruya parte de la red.

La razón por la que las redes neuronales son tolerantes a los fallos es que tienen su información distribuida en las conexiones entre neuronas, existiendo cierto grado de redundancia en este tipo de almacenamiento. La mayoría de los

ordenadores algorítmicos y sistemas de recuperación de datos almacenan cada pieza de información en un espacio único, localizado y direccionable. En cambio, las redes neuronales almacenan información no localizada. Por lo tanto, la mayoría de las interconexiones entre los nodos de la red tendrán sus valores en función de los estímulos recibidos, y se generará un patrón de salida que represente la información almacenada.

7.7.4 Operación en tiempo real.

Una de las mayores prioridades, casi en la totalidad de las áreas de aplicación, es la necesidad de realizar procesos con datos de forma muy rápida. Las redes neuronales se adaptan bien a esto debido a su implementación paralela. Para que la mayoría de las redes puedan operar en un entorno de tiempo real, la necesidad de cambio en los pesos de las conexiones o entrenamiento es mínima.

7.7.5 Fácil inserción dentro de la tecnología existente.

Una red individual puede ser entrenada para desarrollar una única y bien definida tarea (tareas complejas, que hagan múltiples selecciones de patrones, requerirán sistemas de redes interconectadas). Con las herramientas computacionales existentes (no del tipo PC), una red puede ser rápidamente entrenada, comprobada, verificada y trasladada a una implementación hardware de bajo coste. Por lo tanto, no se presentan dificultades para la inserción de redes neuronales en aplicaciones específicas, por ejemplo de control, dentro de los sistemas existentes. De esta manera, las redes neuronales se pueden utilizar para mejorar sistemas en forma incremental y cada paso puede ser evaluado antes de acometer un desarrollo más amplio.

8 ALGORITMOS GENÉTICOS

Los algoritmos genéticos son una técnica de inteligencia artificial que utiliza procedimientos adaptativos, están destinados para resolver problemas de búsqueda que satisfagan ciertos requisitos y se encuentran inspirados en los mecanismos de la evolución biológica basándose en el principio de selección natural y de los códigos genéticos de las especies.

Los Algoritmos Genéticos (AG) tienen como entrada una población de individuos llamados cromosomas, que son generados aleatoriamente y presentan las posibles soluciones al problema, o bien, si se cuenta con algún conocimiento sobre la distribución óptima se puede utilizar esta información para crear parte del conjunto inicial de soluciones potenciales (Michalewicz, 1995; Yang y Korfhage, 1994). Estos individuos van cambiando (evolucionando) en sucesivas iteraciones llamadas generaciones, mediante procesos de selección, cruce y mutación. Al final las soluciones terminan cuando el sistema deja de mejorar o cuando se alcanza un número máximo prefijado de generaciones.

La salida del AG será el mejor individuo de la población final o una combinación de los mejores cromosomas de ella.

La optimización de la estructura de una red neuronal puede ser clasificada de acuerdo a la meta a alcanzar. Algunos esquemas han propuesto la optimización de los pesos sinápticos, otros afirman que lo más importante es la arquitectura y otros acercamientos han incluido funciones de activación y reglas de aprendizaje. Sin embargo el área más interesante de nuevas investigaciones radica en la combinación de estos enfoques de optimización.

Para el diseñador de la red uno de los aspectos más relevantes de su trabajo es la de encontrar el número de capas ocultas, neuronas y funciones de activación con las que se debe configurar la red. El entrenamiento también es un aspecto importante para lograr una buena solución, sin embargo existen técnicas basadas en programación no lineal que han demostrado ser muy efectivas, y por tanto, esta labor es asignada a algoritmos especializados en aproximar los pesos adecuados para cada una de las conexiones. El diseñador, por lo tanto, debe concentrarse en el análisis de las topologías candidatas para optimizar el problema.

Una teoría que ha ganado terreno en el campo de la investigación de las redes neuronales es la búsqueda de pesos, capas ocultas, neuronas y funciones de activación por medio de algoritmos genéticos.

El funcionamiento general de los AG es el siguiente: tratar de mantener una población de individuos, cada uno de ellos distinguido por un código genético que lo caracteriza unívocamente, y simular una evolución de dicha población a lo largo del tiempo, basada en la aparición de nuevos individuos como resultado de cruces, mutaciones y reproducciones de los individuos antiguos. Cada uno de los individuos presenta una posible solución al problema y la evolución se realiza de manera que los individuos de cada generación tengan una mayor probabilidad de ser mejores soluciones que los individuos de la generación anterior.

8.1 ESQUEMA BÁSICO

En la naturaleza todo el proceso de evolución biológica se hace de forma natural pero para aplicar el algoritmo genético al campo de la resolución de problemas habrá que seguir una serie de pasos. Una premisa es conseguir que el tamaño de la población sea lo suficientemente grande para garantizar la diversidad de soluciones. Se aconseja que la población sea generada de forma aleatoria para obtener dicha diversidad. En caso de que la población no sea generada de forma aleatoria habrá que tener en cuenta que se garantice una

cierta diversidad en la población generada. Los pasos básicos de un algoritmo genético son:

- ◆ Evaluar la puntuación de cada uno de los cromosomas generados.
- ◆ Permitir la reproducción de los cromosomas siendo los más aptos los que tengan más probabilidad de reproducirse.
- ◆ Con cierta probabilidad de mutación, mutar un gen del nuevo individuo generado.
- ◆ Organizar la nueva población.

Estos pasos se repetirán hasta que se dé una condición de terminación. Se puede fijar un número máximo de iteraciones antes de finalizar el algoritmo genético o detenerlo cuando no se produzcan más cambios en la población (convergencia del algoritmo). Esta última opción suele ser la más habitual.

8.2 PARÁMETROS DE LOS ALGORITMOS GENÉTICOS

Para el estudio de los algoritmos genéticos hay que tener en cuenta una serie de parámetros:

1. Tamaño de la Población

Este parámetro nos indica el número de cromosomas que tenemos en nuestra población para una generación determinada. En caso de que esta medida sea insuficiente, el algoritmo genético tiene pocas posibilidades de realizar reproducciones con lo que se realizaría una búsqueda de soluciones escasa y poco óptima. Por otro lado si la población es excesiva, el algoritmo genético será excesivamente lento. De hecho estudios revelan que hay un límite a partir del cual es ineficiente elevar el tamaño de la población puesto que no se consigue una mayor velocidad en la resolución del problema.

2. Probabilidad de Cruce

Indica la frecuencia con la que se producen cruces entre los cromosomas padre, es decir, que haya probabilidad de reproducción entre ellos. En caso de que no exista probabilidad de reproducción, los hijos serán copias exactas de los padres. En caso de haberla, los hijos tendrán partes de los cromosomas de los padres. Si la probabilidad de cruce es del 100% el hijo se crea totalmente por cruce, no por partes.

3. Probabilidad de Mutación

Nos indica la frecuencia con la que los genes de un cromosoma son mutados. Si no hay mutación, los descendientes son los mismos que había tras la reproducción. En caso de que haya mutaciones, parte del cromosoma descendiente es modificado y si la probabilidad de mutación es del 100%, la totalidad del cromosoma se cambia. En este caso, no se cambian simplemente unos bits del cromosoma sino que se cambian todos, lo que significa que se produce una inversión en el cromosoma y no una mutación por lo que la población degenera muy rápidamente.

8.3 OPERACIONES DE LOS ALGORITMOS GENÉTICOS

Tras parametrizar el problema en una serie de variables, se codifican en un cromosoma. Todos los operadores utilizados por un algoritmo genético se aplicarán sobre estos cromosomas, o sobre poblaciones de ellos. En el algoritmo genético va implícito el método para resolver el problema. Hay que tener en cuenta que un algoritmo genético es independiente del problema, lo cual lo hace un algoritmo robusto, al resultar útil en cualquier ámbito de acción, pero a la vez débil, pues no está especializado en ninguno. Las soluciones codificadas en un cromosoma compiten para ver cuál constituye la mejor solución (aunque no necesariamente la mejor de todas las soluciones posibles). El ambiente, constituido por las otras soluciones, ejercerá una presión selectiva sobre la población, de forma que sólo los mejor adaptados (aquellos que resuelvan mejor el problema) sobrevivan o leguen su material genético a las siguientes generaciones, igual que en la evolución de las especies. La diversidad genética se introduce mediante mutaciones y

reproducción sexual. Por lo tanto, un algoritmo genético consiste en hallar de qué parámetros depende el problema, codificarlos en un cromosoma, y aplicar los métodos de la evolución: selección y reproducción sexual con intercambio de información y mutaciones que generen diversidad.

Los métodos en que se basa la herramienta de aplicación son aquellos en que se utilizan específicamente en el diseño de la arquitectura de la red (capas y funciones de activación). Y los algoritmos que se utilizaron para realizar la optimización de la estructura son:

- ◆ Traingda: es una función de entrenamiento de red que actualiza los valores de los pesos y bias, de acuerdo con el gradiente descendente con tasa de aprendizaje adaptativa con propagación hacia atrás.
- ◆ Traingdx: es una función de entrenamiento de red que actualiza los valores de los pesos y bias, de acuerdo con el gradiente descendente con momento y tasa de aprendizaje adaptativa con propagación hacia atrás.
- ◆ Trainrp: es una función de entrenamiento de red que actualiza los valores de los pesos y bias, de acuerdo con la resistencia del algoritmo de propagación hacia atrás Resilient
- ◆ Trainlm: es una función de entrenamiento de red que actualiza los valores de los pesos y bias, de acuerdo con la optimización hacia atrás de Levenberg
- ◆ Trainbfg: es una función de entrenamiento de red que actualiza los valores de los pesos y bias, de acuerdo con la el método de propagación hacia atrás BFGS quasi-Newton

A continuación se explicaran cada uno de los procesos u operaciones básicas utilizadas en un AG.

8.4 SELECCIÓN

Los algoritmos de selección serán los encargados de escoger que individuos van a disponer de oportunidades de reproducirse y cuáles no.

Puesto que se trata de imitar lo que ocurre en la naturaleza, se ha de otorgar un mayor número de oportunidades de reproducción a los individuos más aptos. Por lo tanto la selección de un individuo estará relacionada con su valor de ajuste. No se debe sin embargo eliminar por completo las opciones de reproducción de los individuos menos aptos, pues en pocas generaciones la población se volverá homogénea.

8.4.1 Selección por ruleta.

Propuesto por Dejong, es posiblemente el método más utilizado desde los orígenes de los Algoritmos genéticos¹³.

A cada uno de los individuos de la población se le asigna una parte proporcional a su ajuste de una ruleta, de tal forma que la suma de todos los porcentajes sea la unidad. Los mejores individuos recibirán una porción de la ruleta mayor que la recibida por los peores.

Generalmente la población esta ordenada en base al ajuste por lo que las porciones mas grandes se encuentran al inicio de la ruleta. Para seleccionar un individuo basta con generar un numero aleatorio del intervalo (0,1) y devolver el individuo situado en esa posición de la ruleta.

Esta posición se suele obtener recorriendo los individuos de la población y acumulado sus proporciones de ruleta hasta que la suma exceda el valor obtenido.

Es un método muy sencillo, pero ineficiente a medida que aumenta el tamaño de la población y presenta además el inconveniente de que el peor individuo puede ser seleccionado más de una vez.

¹³ Blickle T. and Thiele L. A Comparison of Selection Schemes Used in Genetic Algorithms. Technical Report 11, Computer Engineering and Comunication Network Lab (TIK), Gloriastrasse 35, 8092 Zurich, Switzeland, 1995.

8.4.2 Selección por torneo.

La idea principal de este método consiste en realizar la selección en base a comparaciones directas entre individuos. Existen dos versiones de selección mediante torneo:

- ◆ Determinística
- ◆ Probabilística

En la versión determinística se selecciona al azar un número p de individuos (generalmente se escoge $p=2$). De entre los individuos seleccionados se selecciona el más apto para pasarlo a la siguiente generación.

La versión probabilística únicamente se diferencia en el paso de selección del ganador del torneo. En vez de escoger siempre el mejor se genera un número aleatorio del intervalo $(0,1)$, si es mayor que un parámetro p (fijado para todo el proceso evolutivo) se escoge el individuo más alto y en caso contrario el menos apto. Generalmente p toma valores en el rango de $0.5 < p \leq 1$.

Variando el número de individuos que participan en cada torneo se puede modificar la presión de selección. Cuando participan muchos individuos en cada torneo la presión de selección es elevada y los peores individuos apenas tiene oportunidades de reproducción. Cuando el tamaño del torneo es reducido, la presión de selección disminuye y los peores tienen más oportunidades de ser seleccionados.

Un caso particular es el elitismo global. Se trata de un torneo en el que participan todos los individuos de la población con lo cual la selección se vuelve totalmente determinística. En los procesos evolutivos las hembras seleccionan a los machos mejor dotados que aseguren su descendencia, por su parte los AG involucran en su desarrollo criterios de elitismo por medio de penalizaciones para determinar su aptitud; los cromosomas con el menor número de penalizaciones serán los más aptos. Este criterio se aplica con la finalidad de mantener al mejor individuo de cada población y copiarlo a la

siguiente de esta manera se asegura mantener en cada nueva población al cromosoma con mejor aptitud.

Elegir uno u otro método de selección determinara la estrategia de búsqueda del Algoritmo Genético. Si se opta por un método con una alta presión de selección se centra la búsqueda de las soluciones en un entorno próximo a las mejores soluciones actuales. Por el contrario, optando por una presión de selección menor se deja el camino abierto para la exploración de nuevas regiones del espacio de búsqueda. Existen muchos algoritmos de selección. Unos buscan mejorar la eficiencia computacional, otros el número de veces que los mejores o peores individuos pueden ser seleccionados. Algunos de estos algoritmos son muestreo determinístico, escalamiento sigma, selección por jerarquías, estado uniforme, sobrante estocástico, brecha generacional, etc.

8.4.3 Cruce.

Durante el proceso de fecundación, el espermatozoide y el ovulo se une y reconstruyen en el nuevo organismo la disposición por pares de los cromosomas; la mitad de estos cromosomas procede de cada padre. Este mismo hecho simulan los algoritmos genéticos con el proceso de cruce donde dos cromosomas comparten información genética en pos de crear un nuevo individuo.

Existen multitud de algoritmos de cruce. Sin embargo los más empleados son:


- ◆ Cruce de 1 punto
- ◆ Cruce de 2 puntos
- ◆ Cruce uniforme

8.4.3.1 Cruce de 1 punto.

Es la más sencilla de las técnicas de cruce. Una vez seleccionados dos individuos se cortan sus cromosomas por un punto seleccionando aleatoriamente para generar dos segmentos diferenciados en cada uno de ellos: la cabeza y la cola (Ver **Figura 31**).

Se intercambian las colas entre los dos individuos para generar los nuevos descendientes. De esta manera ambos descendientes heredan información genética de los padres.

Figura 31. Cruce de un punto.




Fuente. Gestal M., Introducción a los algoritmos genéticos, departamento de tecnologías de la información y las comunicaciones, Universidade da Coruña, 1996.

8.4.3.2 Cruce de 2 puntos.

Se trata de una generalización del cruce de 1 punto. En vez de cortar por un único punto los cromosomas de los padres como en el caso anterior se realizan dos cortes. Debería tenerse en cuenta que ninguno de estos puntos de corte coincida con el extremo de los cromosomas para garantizar que se originen tres con el extremo de los cromosomas para garantizar que se originen tres segmentos. Para generar la descendencia se escoge el segmento central de uno de los padres y los segmentos laterales del otro padre (Ver **Figura 32**).

Figura 32. Cruce de dos puntos.



Fuente. Gestal M., Introducción a los algoritmos genéticos, departamento de tecnologías de la información y las comunicaciones, Universidade da Coruña, 1996.


8.4.3.3 Cruce Uniforme.

El cruce uniforme (Ver **Figura 33**) es una técnica completamente diferente de las vistas hasta el momento. Cada gen de la descendencia tiene las mismas probabilidades de pertenecer a uno u otro padre.

Aunque se puede implementar de muy diversas formas, la técnica implica la generación de una máscara de cruce con valores binarios. Si en una de las posiciones de la máscara hay un 1, el gen situado en esa posición en uno de los descendientes se copia del primer padre.

Si por el contrario hay un 0 el gen se copia del segunda padre. Para producir el segundo descendiente se intercambian los papeles de los padres, o bien se intercambia la interpretación de los unos y los ceros de la máscara de cruce.

Figura 33. Cruce uniforme.



Fuente. Gestal M., Introducción a los algoritmos genéticos, departamento de tecnologías de la información y las comunicaciones, Universidade da Coruña, 1996.

8.4.4 Mutación.

Las mutaciones son la materia prima de la evolución. No obstante, sin mutaciones las especies no evolucionarían. La evolución tiene lugar cuando una nueva versión de un gen, que originalmente surge por una mutación, aumenta su frecuencia y se extiende a la especie gracias a la selección natural. En los AG, las mutaciones son quienes permiten crear nuevos individuos, escapar de los mínimos locales, abastecerse de nuevo material genético, y cierto casos mejorar los procesos de elitismo en busca de mejores soluciones.

8.5 VENTAJAS DE LOS ALGORITMOS GENÉTICOS

- ◆ Una clara ventaja es que los algoritmos genéticos son intrínsecamente paralelos, es decir, operan de forma simultánea con varias soluciones, en vez de trabajar de forma secuencial como las técnicas tradicionales. Esto significa que mientras técnicas tradicionales sólo pueden explorar el espacio de soluciones hacia una solución en una dirección al mismo tiempo, y si la solución que descubren resulta subóptima, no se puede hacer otra cosa que abandonar todo el trabajo hecho y empezar de nuevo. Sin embargo, los algoritmos genéticos simplemente desechan esta solución subóptima y siguen por otros caminos.
- ◆ Cuando se usan para problemas de optimización resultan menos afectados por los máximos locales (falsas soluciones) que las técnicas tradicionales. Muchos algoritmos de búsqueda pueden quedar atrapados en los óptimos locales: si llegan a lo alto de una colina del paisaje adaptativo, descubrirán que no existen soluciones mejores en las cercanías y concluirán que han alcanzado la mejor de todas, aunque existan picos más altos en algún otro lugar del mapa, situación que no sucede para algoritmos genéticos.
- ◆ Otra ventaja es su habilidad para manipular muchos parámetros simultáneamente. Resulta interesante en caso de tener varios objetivos a resolver.
- ◆ No necesitan conocimientos específicos sobre el problema que intentan resolver. Realizan cambios aleatorios en sus soluciones candidatas y luego utilizan la función de aptitud para determinar si esos cambios producen una mejora o no.
- ◆ Resulta sumamente fácil ejecutarlos en las modernas arquitecturas masivas en paralelo.
- ◆ Usan operadores probabilísticos, en vez de los típicos operadores determinísticos de las otras técnicas.

8.6 DESVENTAJAS DE LOS ALGORITMOS GENÉTICOS

- ◆ Definir una representación del problema. El lenguaje utilizado para especificar soluciones candidatas debe ser robusto, debe ser capaz de tolerar cambios aleatorios que no produzcan constantemente errores fatales o resultados sin sentido. Se puede solucionar mediante la definición de los individuos como listas de números donde cada número representa algún aspecto de la solución candidata.
- ◆ Pueden tardar mucho en converger, o no converger en absoluto, dependiendo en cierta medida de los parámetros que se utilicen -tamaño de la población, número de generaciones.
- ◆ Pueden converger prematuramente debido a una serie de problemas. Si un individuo que es más apto que la mayoría de sus competidores emerge muy pronto en el curso de la ejecución, se puede reproducir tan abundantemente que merme la diversidad de la población demasiado pronto, provocando que el algoritmo converja hacia el óptimo local que representa ese individuo, en lugar de rastrear el paisaje adaptativo lo bastante a fondo para encontrar el óptimo global. Esto es un problema especialmente común en las poblaciones pequeñas, donde incluso una variación aleatoria en el ritmo de reproducción puede provocar que un genotipo se haga dominante sobre los otros.

9 PARÁMETROS DE LAS RNA Y AG UTILIZADOS EN LA HERRAMIENTA DE APLICACIÓN

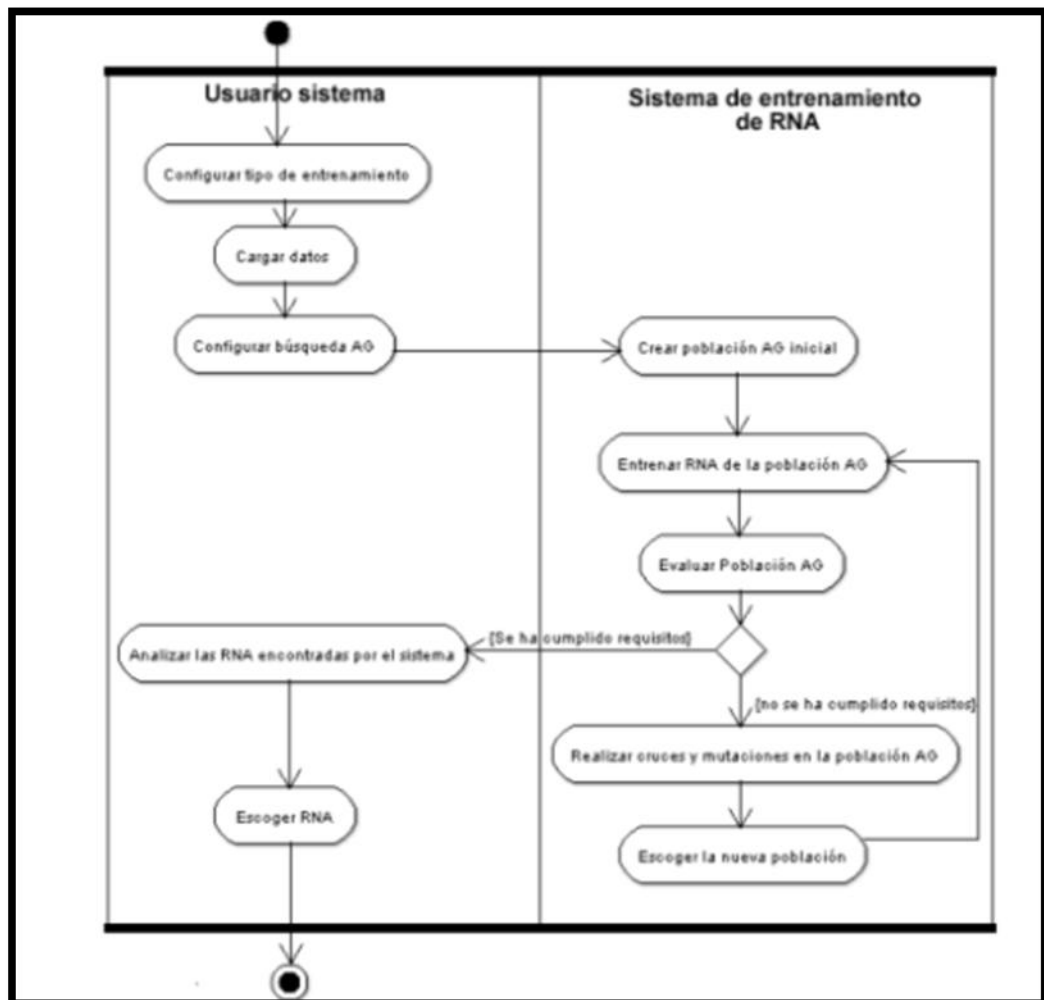
La herramienta de validación de redes neuronales basada en el ajuste genético de parámetros y variación de arquitectura utiliza un algoritmo que realiza los entrenamientos a las diferentes configuraciones, las compara, y regresa al grupo que obtenga el error más bajo. De manera que el trabajo que realiza el algoritmo es una búsqueda sobre la superficie infinita de configuraciones de red neuronal, para encontrar un grupo que se ajuste a los datos de entrenamiento y prueba.

Este algoritmo se programó en Matlab, el cual busca el número de capas ocultas y el número de neuronas en cada una de estas capas, en una red neuronal para que este se ajuste apropiadamente a los valores de solución de un problema y pueda generalizarlo de manera adecuada.

Las fases de desarrollo del software fueron (Ver **Figura 34**):

- ◆ **Conceptualización inicial:** en esta etapa se realizó el estudio de requerimientos del sistema y las diferentes formas de codificación, mutación, cruce y selección.
- ◆ **Diseño e implementación del prototipo inicial:** diseñándose un primer prototipo, sobre el cual se realizaron las sucesivas modificaciones adicionales.
- ◆ **Interacción de refinar el prototipo hasta que sea aceptable:** es esta etapa se realizaron las entregas de los prototipos hasta llegar al prototipo aceptable.
- ◆ **Completar y entrega del prototipo:** una vez encontrado el prototipo más adecuado, se realizó la entrega.

Figura 34. Diagrama de actividades para el diseño del mejor algoritmo genético de aplicación al mejor tipo de red neuronal.



Fuente. Mendez. E., y Mariño. J. Sistema Automático de entrenamiento de Redes Neuronales Artificiales Basados en el Ajuste Genético de Parámetros y Variación de Arquitectura. Proyecto de grado presentado ante la Universidad Industrial de Santander (Bucaramanga, Colombia), como requisito para obtener el título de ingenieros de Petróleos.2008.

Para la obtención del diseño del algoritmo genético se realizaron distintas comparaciones y validaciones del comportamiento del algoritmo con tres pruebas diferentes de las cuales se tuvieron conocimiento suficiente sobre su solución para la realización de las comparaciones. Estas comparaciones incluyeron el error promedio absoluto o el error promedio relativo según sea el caso escogido para guiar la evolución del algoritmo, el error promedio absoluto, (o error de la medición promedio), la tasa de ajuste indicando el porcentaje de

semejanza entre los datos reales y los simulados y los errores cometidos por la red neuronal.

El algoritmo recibe como parámetros¹⁴:

- ◆ Entradas: estructura de datos que contiene todos los datos de entrada que se utilizaran para el entrenamiento de las redes neuronales probadas por el algoritmo.
- ◆ Salidas: estructuras de datos que contiene las salidas correspondientes a cada entrada.
- ◆ Población: cantidad de individuos que conforman la población del algoritmo genético.
- ◆ Probabilidad de cruce: es un valor entre 0 y 1 que indica la probabilidad de que un individuo de la población se cruce y genere un nuevo individuo.

Probabilidad de mutación: es un parámetro que indica la probabilidad de que un individuo sufra una mutación. Una mutación en este algoritmo es un cambio aleatorio en un valor del gen que representa una solución, esto se utiliza para generar soluciones diferentes, en el caso en el que el algoritmo este convergiendo a un mínimo local, la mutación podría generar una solución fuera del rango al que se dirige este; si la mutación genera una solución buena le indicara al algoritmo un nuevo cambio de búsqueda.

¹⁴ GALVIS, L; Y OCHOA, C. Desarrollo de una herramienta software utilizando redes neuronales artificiales para estimar propiedades del comportamiento mecánico de arenas limpias pertenecientes a una cuenca Colombiana. Proyecto de grado presentado ante la Universidad Industrial de Santander (Bucaramanga, Colombia), como requisito para obtener el título de ingenieros de Petróleos. 2006.

- ◆ Máximo número de capas: este parámetro indica cual será el número máximo de capas ocultas que podrá tener una red neuronal.
- ◆ Máximo número de neuronas por capa: este parámetro indica cual será el número máximo de neuronas que podrá tener una capa oculta.
- ◆ Máximo número de generaciones: este será el número de veces que itera el algoritmo genético.

Tolerancia al error: es un porcentaje que indica hasta qué valor se valida una respuesta. Por ejemplo si se ingresa 20, la tolerancia será de 20% y si un resultado se encuentra por debajo de este límite será tomado como un acierto.

Número de entrenamientos: señala el número de veces que será entrenada una configuración de red. El entrenamiento de las redes neuronales inicial con pesos aleatorios, por esto no puede descartarse una configuración de red con solo entrenamiento que haya tenido malos resultados; se debe entrenar varias veces para encontrar una configuración de pesos que se adecue mejor al problema.

El algoritmo genético dependiendo de los parámetros con los que sea ejecutado requiere de una gran cantidad de tiempo de procesamiento, el tiempo necesario para una ejecución con 100 generaciones, tamaño de población 100 y 15 entrenamientos por configuración, fue de 6 horas 32 minutos. El algoritmo regresa una estructura de datos que contiene la última generación del algoritmo genético; esta estructura contiene cada uno de los individuos, sus respectivos errores, y la red neuronal ya entrenada para cada caso.

El primer grupo de datos de adjunción al entrenamiento del algoritmo genético consistió en un conjunto de valores dinámicos no lineales, para determinar comportamientos de émbolos en un motor de combustión interna¹⁵.

El segundo grupo de datos consistió en la determinación del patrón de flujo multifásico promedio presente en una tubería a partir de los datos históricos de producción, con el fin de calcular la caída de presión¹⁶.

Y el tercero consistió en un grupo de datos de un sistema para el reconocimiento de rostros obtenidos del grupo de investigación en ingeniería biomédica GIB.

Los resultados obtenidos mediante la aplicación del algoritmo, demostró ser muy satisfactorio, superando los resultados obtenidos al realizar una configuración a prueba y error, donde el éxito está determinado en gran parte por el azar.

Uno de los factores críticos en la configuración/entrenamiento de redes neuronales es el tiempo que se requiere para realizar la búsqueda y llegar a un resultado que cumpla las condiciones que fueron establecidas. Esto fue un aspecto que fue considerado de manera especial en la realización del algoritmo y que logro ser controlado para que las búsquedas se produjeran en un tiempo razonable.

La configuración del algoritmo genera resultados satisfactorios, sin embargo se recomienda a las nuevas herramientas de inteligencia artificial, adicionar nuevos datos de entrenamiento que mejoren cada vez más el tiempo mínimo y la efectividad de la red estimada.

¹⁵ U. Chinchilla, G. Pérez. Herramienta software para la identificación de sistemas dinámicos no lineales, Universidad industrial de Santander, Facultad ingenierías Físico Mecánicas, 2007.

¹⁶ J. Flores, F. Porras, Determinación del patrón de flujo multifásico en tuberías de recolección de Petróleo Emulsionado, a Partir de los Datos Históricos de Producción Apoyado en una Aplicación con Redes Neuronales Artificiales. Universidad industrial de Santander, Facultad ingenierías Físico Mecánicas, 2007.

Finalmente los datos de adición al algoritmo genético determinados son:

Tabla 7. Configuración ayuda para la configuración del algoritmo genético en el entrenamiento de las redes neuronales.

Tamaño de la población	20
Población de mutación	0.1
Probabilidad de cruce	0.8
Máximo de capas	4
Máximo de neuronas	10
Numero de entrenamientos	30
Algoritmo de entrenamiento	Trainilm
Generaciones	20
Tolerancia error	0.01

Fuente. Mendez. E., y Mariño. J. Sistema Automático de entrenamiento de Redes Neuronales Artificiales Basados en el Ajuste Genético de Parámetros y Variación de Arquitectura. Proyecto de grado presentado ante la Universidad Industrial de Santander (Bucaramanga, Colombia), como requisito para obtener el título de ingenieros de Sistemas.2008.

10 HERRAMIENTA DE INTELIGENCIA ARTIFICIAL ORION

“LA HERRAMIENTA ORION” apoyada en el sistema automático de entrenamiento de redes neuronales artificiales basado en el ajuste genético de parámetros y variación de arquitectura que fue desarrollado en MATLAB 7.5.0 R2007b descrita en el capítulo anterior. es la herramienta de estimación que se utilizara para el desarrollo de este proyecto, ya que incluye funciones especializadas en el manejo de las redes, y a su vez presenta buenos resultados de los entrenamientos realizados por las funciones de MATLAB¹⁷.

Son varios los procesos que realiza el sistema durante el estudio de los datos de un problema particular, los cuales se explican en el ANEXO 1.

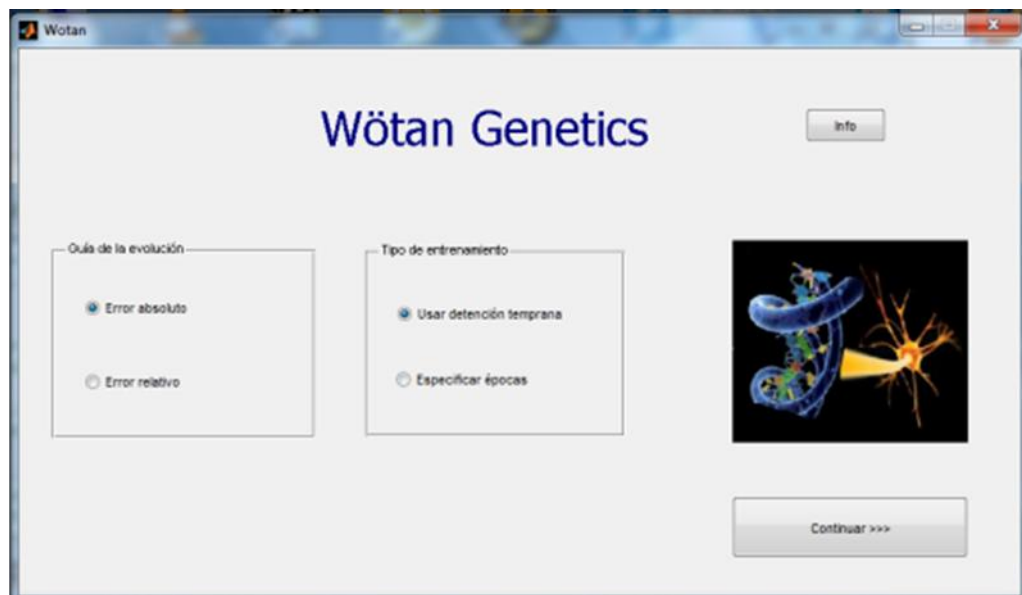
Lo primero que inicia el programa es un menú de selección de los parámetros con los cuales se va a guiar la búsqueda, dependiendo de la selección de estos parámetros será el comportamiento del algoritmo genético y la forma de cargar los datos usada (Ver **Figura 35**).

El tipo de error le indica al algoritmo genético la manera cómo va a evaluar el desempeño de una configuración, las opciones que se muestran para guiar la evolución son mediante el error absoluto o un error relativo porcentual. La selección del tipo de error a usar depende de la naturaleza de los datos de entrenamiento a usar. Para lo cual por el tipo de datos a trabajar el error relativo es escogido para la configuración en esta investigación, debido a que ocasiona que los datos se distribuyan más o menos con simetrías alrededor de un valor promedio y se refleja por su grado de precisión.

¹⁷ GALVIS, L; Y OCHOA, C. Desarrollo de una herramienta software utilizando redes neuronales artificiales para estimar propiedades del comportamiento mecánico de arenas limpias pertenecientes a una cuenca Colombiana. UIS. 2006

En el tipo de entrenamiento a seleccionar se refieren a los tiempos en los que se va a realizar el entrenamiento de la red neuronal que puede ser con detención temprana o especificaciones por épocas, para lo cual por facilidad y tipo de entrenamiento que se necesita en esta estimación se utilizó la detención temprana, lo que indica que se deben tener seleccionados los conjuntos de datos necesarios para este tipo de entrenamiento.

Figura 35. Ventana inicial del programa de redes Neuronales



Fuente. GALVIS, L; Y OCHOA, C. Desarrollo de una herramienta software utilizando redes neuronales artificiales para estimar propiedades del comportamiento mecánico de arenas limpias pertenecientes a una cuenca Colombiana. UIS. 2006.

La variación de los datos escogidos para el grupo de entrenamiento, prueba y verificación de la red, permite mejorar o desmejorar los parámetros finales. Del mismo modo, la respuesta esperada en la simulación de los datos depende esencialmente de la selección de los mismos, en donde se escoja un set de datos representativos para cada grupo, valorando valores máximos y mínimos de los registros para los cuales se presenta una misma medición AFI.

Seguidamente se solicita el tipo de normalización que se quiere utilizar en las entradas y salidas respectivamente: para lo cual es escogida la Tangente

Hiperbólica debido a que este tipo de normalización ajusta los datos en un rango entre menos uno y uno $[-1,1]$ (Ver **Figura 36**).

La interfaz también solicita el número de entradas y de salidas. Después de llenar estos datos, se pueden cargar los archivos de datos en los que se encuentran agrupadas las entradas en sus valores originales.

Para la carga de datos se definió un sencillo formato en el cual cada uno de los conjuntos de entrenamiento se guarda en un archivo de texto plano con extensión .dat y mediante el programa se realiza la carga de cada uno de estos conjuntos.

Figura 36. Carga de datos para detención temprana

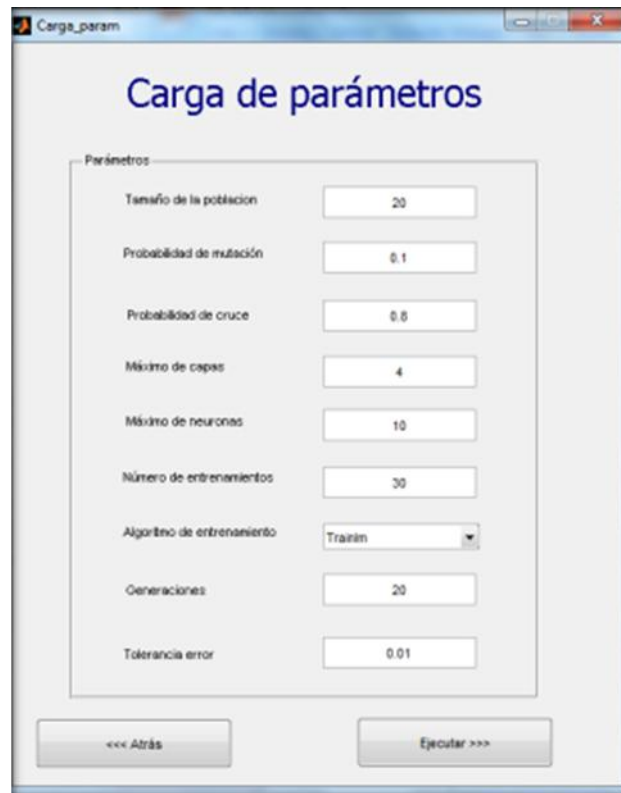


Fuente. GALVIS, L; Y OCHOA, C. Desarrollo de una herramienta software utilizando redes neuronales artificiales para estimar propiedades del comportamiento mecánico de arenas limpias pertenecientes a una cuenca Colombiana. UIS. 2006.

El siguiente paso consiste en especificar el espacio de búsqueda del algoritmo genético y los demás datos que se van a usar en el problema, para esto se tiene: Tamaño de la población, Probabilidad de mutación, Probabilidad de cruce, Máximo número de capas, Máximo número de neuronas por capa, Número de entrenamiento para cada red, Algoritmo de entrenamiento, Número de generaciones y Tolerancia al error. Estos datos ya vienen cargados por

defecto, como referencia al trabajo realizado por Mendez. E., y Mariño. J en el 2008, por lo cual las estimaciones se hicieron en base a estas valoraciones predeterminadas (Ver **Figura 37**).

Figura 37. Carga de parámetros del algoritmo genético



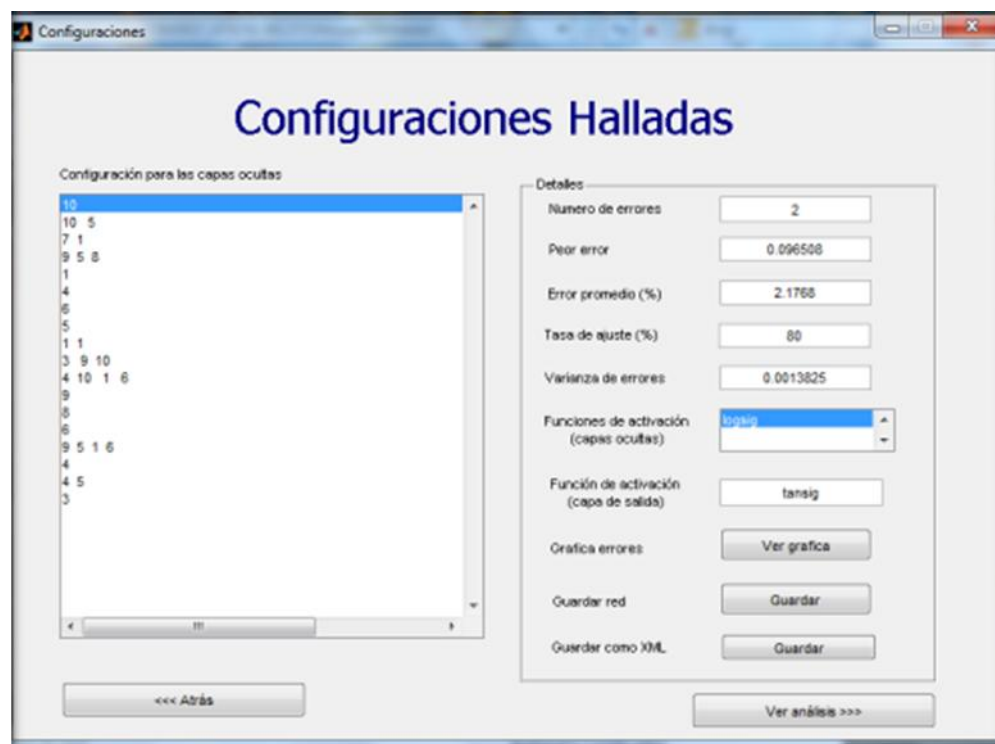
Parámetros	
Tamaño de la población	20
Probabilidad de mutación	0.1
Probabilidad de cruce	0.8
Máximo de capas	4
Máximo de neuronas	10
Número de entrenamientos	30
Algoritmo de entrenamiento	Train
Generaciones	20
Tolerancia error	0.01

Fuente. GALVIS, L; Y OCHOA, C. Desarrollo de una herramienta software utilizando redes neuronales artificiales para estimar propiedades del comportamiento mecánico de arenas limpias pertenecientes a una cuenca Colombiana. UIS. 2006.

Luego del proceso de búsqueda se muestran las soluciones encontradas, ordenadas de acuerdo al número de errores cometidos al evaluar cada configuración con los datos de prueba. En la parte izquierda se muestran las configuraciones finales encontradas en el algoritmo genético de acuerdo a un arreglo donde cada posición representa una capa oculta usada, mientras que el número representa las neuronas ocultas utilizadas en cada capa (Ver **Figura 38**).

Al seleccionar cada una de estas configuraciones, se muestran algunos detalles sobre el comportamiento de las mismas, tales como: Configuración de las capas ocultas, Numero de errores, Peor error, Error promedio, Varianza de los errores, Funciones de activación, Grafica de errores, Guardar red y Guardar como XML.

Figura 38. Ventana de configuraciones



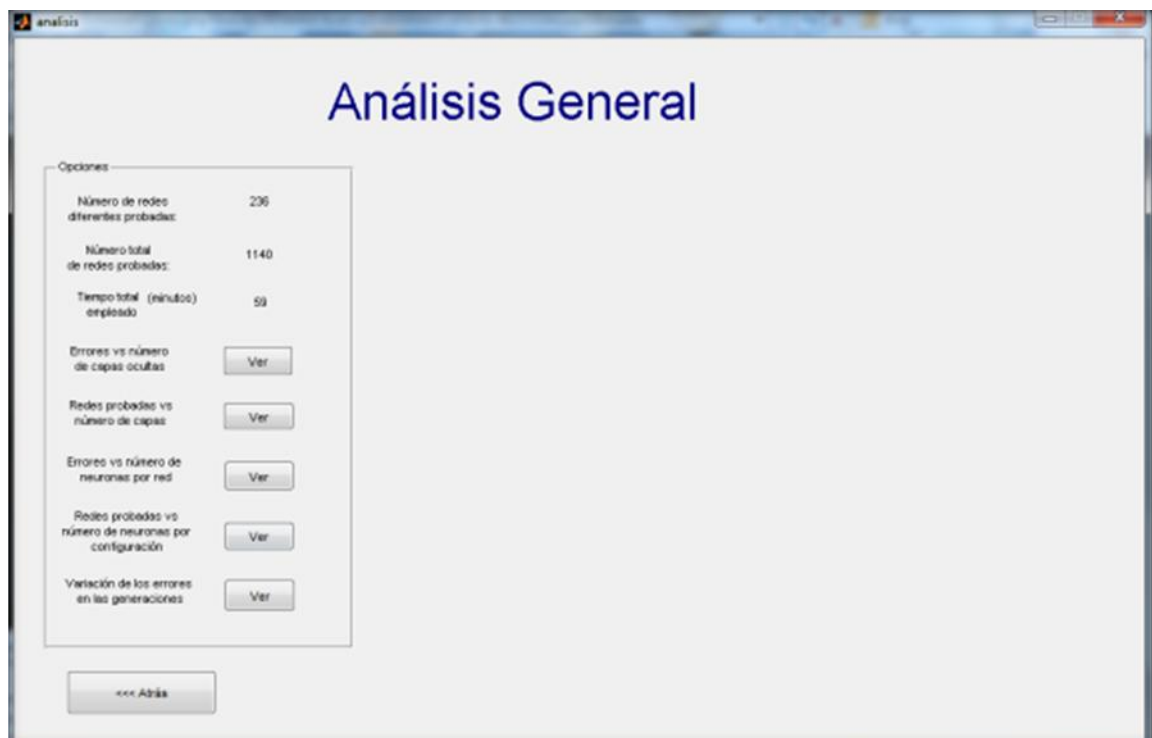
Fuente. GALVIS, L; Y OCHOA, C. Desarrollo de una herramienta software utilizando redes neuronales artificiales para estimar propiedades del comportamiento mecánico de arenas limpias pertenecientes a una cuenca Colombiana. UIS. 2006.

Al pulsar el botón Ver análisis, la herramienta presenta un análisis estadístico de la búsqueda realizada por el algoritmo genético: Error vs número de capas ocultas, Redes probadas vs número de capas, Errores vs número de neuronas por red, Redes probadas vs número de neuronas por configuración, Variación de los errores en las generaciones (Ver **Figura 39**).

Debido a que la herramienta, proporciona ciertos parámetros de valoración, se han priorizado cuatro factores en la selección de la red a escogerse como evaluación final, para cada uno de los casos planteados. Para este trabajo se

mostrarán solo las mejores estimaciones de red que presenten una buena tasa de ajuste; para lo cual implícitamente se presenta un aumento en el número de capas ocultas que generan mejores resultados, por tener más nivel de procesamiento de los datos para la solución del problema y una valoración de error mínimo. Recordando que esta selección depende también de la experiencia y conocimiento de los datos a trabajar, por el configurador y que aunque la herramienta es bastante robusta no significa que sea la mejor de todas las soluciones posibles si no la mejor solución que se genere a partir de la configuración generada por el algoritmo genético.

Figura 39. Análisis general de la red



Fuente. GALVIS, L; Y OCHOA, C. Desarrollo de una herramienta software utilizando redes neuronales artificiales para estimar propiedades del comportamiento mecánico de arenas limpias pertenecientes a una cuenca Colombiana. UIS. 2006.

Finalmente se estima la propiedad en toda la sección del pozo, a partir de la configuración de la red, por medio del probartdat.m (Ver **Figura 40**), especificando el tipo de normalización, para lo cual fue escogida la Tangente Hiperbólica debido a que este tipo de normalización ajusta los datos en un rango entre menos uno y uno $[-1,1]$, máximos y mínimos y la carga de los datos

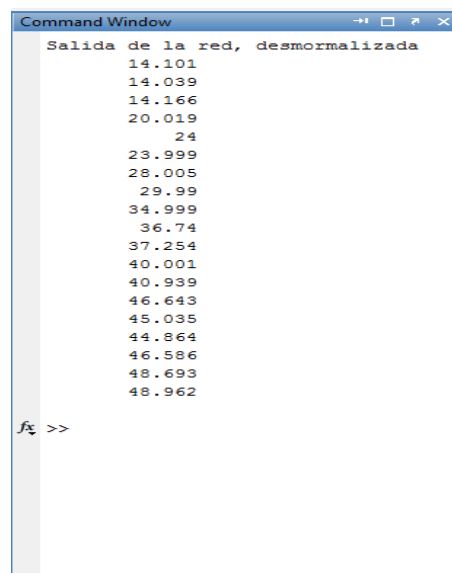
a estimar en un archivo de texto plano con extensión .dat y se prueba los datos del archivo (Ver **Figura 41**), para lo cual se tabula para el análisis posterior.

Figura 40. Extensión probardat.m



Fuente. GALVIS, L; Y OCHOA, C. Desarrollo de una herramienta software utilizando redes neuronales artificiales para estimar propiedades del comportamiento mecánico de arenas limpias pertenecientes a una cuenca Colombiana. UIS. 2006.

Figura 41. Salida de los datos a partir de la Extensión probardat.m



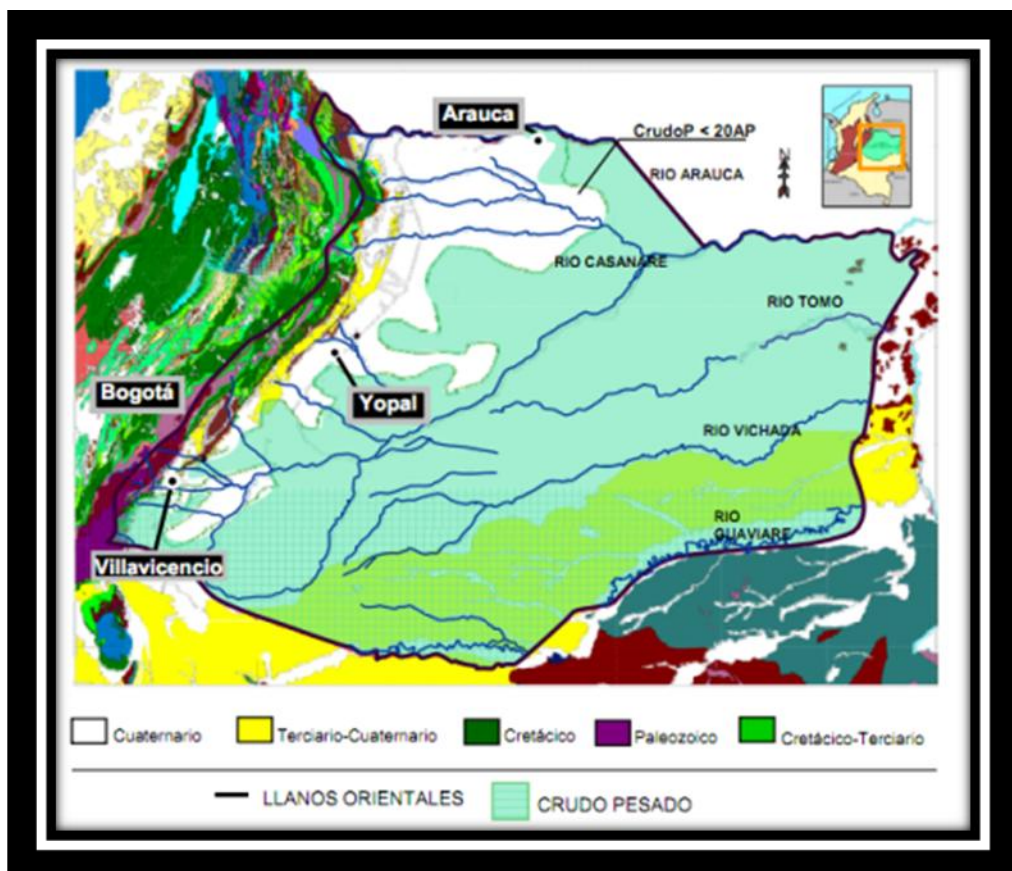
Fuente. GALVIS, L; Y OCHOA, C. Desarrollo de una herramienta software utilizando redes neuronales artificiales para estimar propiedades del comportamiento mecánico de arenas limpias pertenecientes a una cuenca Colombiana. UIS. 2006.

11 GENERALIDADES DE LAS CUENCAS

11.1 CUENCA DE LOS LLANOS ORIENTALES Y PIEDEMORTE LLANERO

La cuenca de los Llanos Orientales se encuentra en la región del centro del país y está conformada por los departamentos del Meta, Arauca, Casanare, Vichada, Guainía y Guaviare (Ver **Figura 42**).

Figura 42. Ubicación de la cuenca de los Llanos Orientales



Fuente. http://www.anh.gov.co/privados/caracteristicas_cuenca.pdf

De los 220.000 Km² de la Cuenca de los Llanos 153.000 Km² corresponden al área de prospectividad de crudos pesados donde se ha adquirido gran cantidad de información desde 1994. Con 1,360 pozos perforados.

11.1.1 Estratigrafía.

La Cordillera Oriental de Colombia se funda sobre un basamento precámbrico, afectada por eventos orogénicos en el proterozoico, eventos ígneos y procesos sedimentarios en el Mesozoico y procesos sedimentarios en el Terciario. La Cuenca presenta estilos tectónicos bien definidos, que separan o ponen en contacto unidades estratigráficas a lo largo de un tren estructural que sigue un patrón regional NE- SW.

Rocas sedimentarias del Cretáceo ocupan extensas zonas de la Cordillera Oriental, las cuales se manifiestan en algunos sitios de la Serranía del Perija como conglomerados basales y en otros como capaz de calizas y lutitas, las cuales reposan discordantemente sobre rocas del Grupo Quetame y del Grupo Farallones. Estas secuencias litológicas que comienzan con conglomerados, areniscas y limolitas fluviales y deltaicas, también cuentan con areniscas, calizas y limolitas marinas. La sedimentación continúa con lutitas, calizas, areniscas e intercalaciones locales de limonitas silíceas, mantos de carbón, evaporitas y rocas fosfóricas.

Los ciclos estratigráficos o los hem Ciclos que los componen constituyen las formaciones que han sido definidas en la Cuenca de los Llanos (Ver **Figura 43**), donde puede observarse que las formaciones productoras son Mirador, Barco y Guadalupe, mientras que las formaciones sellos son los Cuervos y Carbonera:


- ◆ La Formación Une está constituida esencialmente por areniscas con delgadas intercalaciones lodosas. Se identifican depósitos de canales fluviales, estuarinos, depósitos de llanura de inundación y de relleno de estuarios o bahías. De base a tope hay una transición de ambientes continentales a transicionales. Se depositó durante un aumento en A/S o un evento transgresivo. El tope es una superficie de inundación.

- ◆ La Formación Gachetá está constituida por lodolitas con delgadas intercalaciones arenosas, hacia el norte y sureste de la cuenca la proporción de arenas se incrementa considerablemente. Se depositó en una plataforma marina somera durante una disminución en A/S o evento regresivo. Al tope se identifica una superficie de inconformidad en la mayor parte de la Cuenca de los Llanos.
- ◆ La Formación Guadalupe está constituida por areniscas con delgadas intercalaciones lodosas. Su evolución estratigráfica y ambiental es más compleja de la comúnmente reconocida. La sección basal se depositó en ambientes estuarinos durante un aumento en A/S (esta se interpreta como un relleno de valles de incisión). El intervalo medio se depositó en un ambiente de plataforma marina somera durante una disminución en A/S o un evento progradacional; este evento termina con el desarrollo de una superficie de inconformidad Intra-Guadalupe. El intervalo superior se depositó en ambientes estuarinos y de plataforma marina somera durante un aumento en A/S.
- ◆ La Formación Barco es un intervalo esencialmente arenoso depositado en canales fluviales y estuarinos durante un aumento en A/S o evento transgresivo. La Formación Los Cuervos corresponde a un intervalo de lodolitas con intercalaciones arenosas de diferente espesor, se depositó en una llanura de inundación o llanura costera superior durante una disminución en A/S.
- ◆ La formación Los Cuervos se caracteriza por ser una secuencia siliciclastica de grano mas fino constituida por litoarenitas arcillosas a muy arcillosas, color verde a gris verdoso de grano muy fino y fino y lodolitas masivas plásticas, color verde oliva gris verdoso y gris oscuro localmente arenosas o carbonosas. Las arenitas presentan estratificación cruzada y son mineralógicamente inmaduras mientras que texturalmente son más maduras. El contacto inferior con la formación

Barco es transicional y el superior con la formación Mirador es erosivo neto.

- ◆ La Formación Mirador está constituida por areniscas con delgadas intercalaciones lodosas hacia el tope. Se identifican depósitos de canales fluviales y estuarinos y de rellenos de bahías o estuarios; se observa una transición de ambiente continental a transicional de base a tope. El Mirador se depositó durante un aumento en A/S y se interpreta como un relleno de valles de incisión.
- ◆ La Formación Carbonera está constituida por intercalaciones de lodolitas con areniscas depositadas en ambientes continentales y transicionales. Se identificaron cinco ciclos estratigráficos de baja frecuencia, en donde los hemiciclos de disminución en A/S o eventos progradacionales corresponden a los miembros pares del Carbonera (C10, C8, C6, C4 y C2) y los hemiciclos de aumento en A/S o eventos agradacionales corresponden a los miembros impares del Carbonera (C9, C7, C5, C3 y C1).
- ◆ La Formación León generalmente está constituida por lodolitas con delgadas intercalaciones de areniscas, las cuales se hacen mas frecuentes hacia el tope de la Formación. El ambiente de corresponde a lagos, lagunas costeras, bahías o estuarios. El León se depositó durante una disminución en A/S o evento progradacional.
- ◆ Sobre la formación León se deposita la formación Guayabo que consta de una serie de conglomerados, arenas y arcillolitas rojas de origen continental. Es un depósito asociado con el levantamiento de la Cordillera Oriental.

Figura 43. Modelo estratigráfico y sistemas petrolíferos de la cuenca de los Llanos Orientales



Fuente. http://www.anh.gov.co/privados/caracteristicas_cuenca.pdf

11.2 CUENCA DEL CATATUMBO

La Cuenca Catatumbo se localiza en la parte noreste de Colombia. Está limitada por la Serranía del Perijá y el Macizo de Santander al oeste y los Andes de Mérida al sureste. La convergencia de estos dos elementos estructurales delimita su extensión hacia el sur.

La mayoría de los pozos perforados en el área han presentado shows de hidrocarburos. La cobertura sedimentaria y productiva de la Cuenca Catatumbo, que en algunos sitios sobrepasa los 15 000 pies de espesor, está compuesta por rocas que van desde el Cretácico Inferior hasta el reciente. El basamento cristalino consta de rocas ígneas y metamórficas.

La Cuenca Catatumbo ha sido interpretada como una cuenca de antepaís originada por la colisión de las placas Caribe y Suramérica durante el Mioceno superior-Plioceno, colisión que explicaría el levantamiento de las áreas montañosas limítrofes (Perijá-Santander y Andes de Mérida). La tectónica compresiva quedó reflejada por la presencia de fallas inversas en sus márgenes, las cuales involucran basamento y fallas de bajo ángulo (cabalgamientos), que despegan en determinados intervalos pelíticos del Cretácico superior (formaciones Mito-Juan y Colón). En la parte central de la cuenca se pueden observar estructuras en flor (Río Zulia) asociadas con fallas

de desplazamiento lateral. La Cuenca del Catatumbo es la extensión suroccidental de la prolífica Cuenca de Maracaibo y se considera una cuenca moderadamente explorada.

11.3 ESTRATIGRAFÍA

El registro sedimentario de la cuenca del Catatumbo sobrepasa los 15.000 pies de espesor e involucra rocas con un amplio rango de edad desde el Jurásico hasta Reciente.

EL marco estratigráfico en el área de Tibú se inicia como un evento transgresivo durante el Neocomiano, representado por el Grupo Uribante y seguido de máxima duración durante el Turoniano correspondiente a la sedimentación de shales y calizas de las formaciones Capachos y la Luna. Luego de un periodo de somerización y paulatinamente se da inicio a un ciclo regresivo durante el Paleoceno que permite la acumulación de sedimentos en un ambiente de aguas marinas somera, de dominio de deltas con influencia marina local y desarrollo amplio de llanuras de inundación con las formaciones Catatumbo y Barco. A finales del paleoceno y hasta finales del Eoceno medio, se presenta un marcado dominio de facies continentales caracterizado por sedimentos fluviodeltáicos de las formaciones lo Cuervos y Mirador que enmarcan la finalización del ciclo regresivo. Durante el Oligoceno y Mioceno se da inicio a un nuevo evento de carácter transgresivo presentando por depósitos marginales marinos y shales marinos de las formaciones Carboneras y León. Finalmente y tras una fuerte actividad tectónica la sección es cubierta por depósitos continentales durante el Plió – Pleistoceno. La formación León se ha convertido por sus características litológicas en el sello regional par la cuenca. La suprayacen las formaciones Guayabo y Necesidad.

A continuación se presenta una descripción generalizada de las unidades estratigráficas reportadas para la cuenca del Catatumbo (Ver **Figura 44**):

- ◆ Formación Tibú está localizada en Colombia en la cabecera del Río Tibú. Según Notestein et al (1994), litológicamente está constituida por lodolitas de color gris oscuro, negro y marrón con laminación plano

paralela, fisibles, con abundantes restos de conchas y de peces; intercalada de pequeños niveles de calizas lumaquèlicas en bancos de 30 cm. Con estratificación ondulosa y cuarzoarenitas grises, calcáreas, con abundantes fósiles, bioturbadas en bancos gruesos macizos.


- ◆ La formación Mercedes se encuentra localizada en el Valle de las Mercedes concesión Barco. Según Notestein et al (1994), litológicamente está constituida por calizas arenosas y fosilíferas intercaladas con shales, dolomitas y areniscas. Las calizas se clasifican en un rango entre *mudstones* y *grainstones*. Se presentan en capas delgadas, ricas en materia orgánica con abundantes foraminíferos planetónicos.
- ◆ La formación Aguardiente consiste predominantemente de cuarzoareniscas de grano grueso con niveles de glauconita y fosfatos intercaladas con shales y calizas. Algunos shales presentan alto contenido de materia orgánica y pueden ser potenciales generadores en el área.
- ◆ La formación la Luna consiste en calizas delgadas grises oscuras intercaladas grises oscuras intercaladas con shales. Hacia la parte inferior presenta *mudstone* gris oscuro que ocasionalmente se presenta como lentes o concreciones intercalado con lodolitas calcáreas grises oscuras, laminadas, en capas con estratificación plano paralela ondulosa, ricas en materia orgánica.
- ◆ La formación Capacho se encuentra localizada en el Rio Cogollo (Venezuela). Litológicamente está constituida por lodolitas grises oscuras a negras, con impresiones de bivalvos y restos de peces; intercaladas con lodolitas areniscas grises a marrones, calcáreas bioturbadas, calizas lumaquèlicas grises, onduladas y calizas micríticas.

- ◆ La formación Colon está compuesta por lodolitas fisibles, grises oscuras, ligeramente calcáreas. Hacia la base se presenta una arenisca glauconítica que contiene foraminíferos retrabajados y restos de peces.
- ◆ La formación Mito Juan consiste principalmente en lodolitas fisibles grises verdosas, lodolitas limolíticas, limolitas y calizas que llegan a ser mas frecuentes hacia la parte superior.
- ◆ La formación del Catatumbo consiste de intercalaciones de lodolitas fisibles gris oscuras y arcillolitas un tanto carbonosas. Se presentan localmente capas de carbón. Hacia la base y parte media de la sección son frecuentes las intercalaciones de areniscas micáceas de carácter lenticular.
- ◆ La formación Barco está localizada en el flanco oriental del anticlinal de Petrolea. Consiste de areniscas de grano fino a medio intercaladas con arcillolitas. Estas areniscas presenta por lo general, un contenido de arcillas menos que las areniscas de la formación Catatumbo.
- ◆ La formación los Cuervos consiste en general de shales con capas de areniscas delgadas, limolitas y mantos de carbón.
- ◆ La formación Mirador está constituida por cuarzoarenitas de grano fino a medio, blancas en capas hasta de 50 cm, cuneiformes, con laminación inclinada tangencial de bajo ángulo o en artesa, bioturbadas hacia la parte superior, presentan intercalaciones de grano fino a medio, grises, bioturbadas, localmente con intraclastos de lodolita.
- ◆ La formación Carbonera consiste de una secuencia gruesa de intercalaciones de arcillas, shales grises, limolitas, areniscas grano fino a grueso en delgadas capas intercaladas con areniscas y mantos de carbón. Hacia el tope y la base de la formación se presentan capas

delgadas de areniscas glauconíticas y calizas, las cuales registran incursiones marinas.

- ◆ La formación León se encuentra constituida por shales grises con delgadas capas de limolitas y localmente lentes de areniscas.
- ◆ La formación Pleistoceno está constituida por arenas, gravas y arcillas que representan depósitos fluviales y de los abanicos aluviales.

Figura 44 Columna estratigráfica generalizada de la Cuenca del Catatumbo.



Fuente. <http://www.rondacolombia2010.com/imagenes/docs/31fig2.gif>

12 INFORMACIÓN DISPONIBLE PARA EL SECTOR DE APLICACIÓN

Recopilando la información disponible en el laboratorio de mecánica de rocas ECOPETROL – ICP, acerca de las pruebas para las estimaciones AFI, se tiene finalmente la siguiente secuencia de las cuencas, campos y pozos a estudiar (por efecto de confidencialidad, en el desarrollo de este trabajo de grado, se le ha asignado el nombre de campos UIS1 y UIS2) (Ver **Figura 45**).

Figura 45. Cuencas y Campos en los cuales se encuentran estimación AFI de laboratorio.

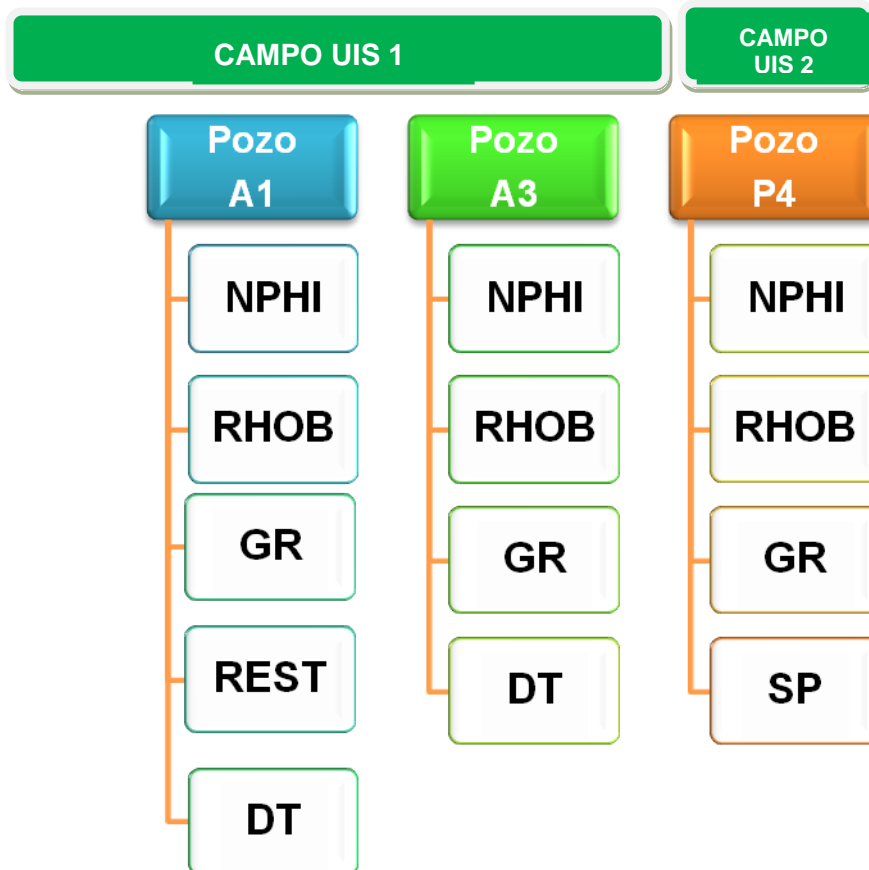


Fuente. Laboratorio de mecánica de rocas Ecopetrol- ICP.

Como variables de entrada se tomaron en cuenta los registros de pozo disponibles que involucran variables que afectan principalmente la estimación del ángulo de fricción interna de la roca.

Para lo cual se tiene el siguiente set (Ver **Figura 46**):

Figura 46. Set de registros disponibles que involucran las variables que afectan la estimación del AFI.



Fuente. El autor

Un planteamiento importante en la búsqueda de las configuraciones de las redes neuronales para la estimación del ángulo de fricción interna, es minimizar las variables de aplicación que permitan simplicidad del modelo con un buen margen de confianza estimado a partir de la herramienta aplicada, propiedad del Instituto Colombiano del Petróleo - Ecopetrol. Por tal motivo, las estimaciones se hicieron bajo diferentes esquemas a nivel de pozo, disminuyendo el número de registros para las cuales se obtiene un resultado confiable de modo que la metodología no solo pueda ser viable si no que presente una ventaja económica y facilitadora en el momento de la aplicación.

13 METOLOGIA DE TRABAJO

Teniendo en cuenta la importancia de un diseño de trabajo ordenado, se propuso un esquema con el fin de cumplir los objetivos planteados y lograr el éxito en esta investigación, donde se trazan las diferentes etapas y los pasos a realizar en cada una (Ver **Figura 47** y **Figura 48**):

13.1 ETAPA DE DOCUMENTACIÓN

En esta primera etapa fundamental en la generación y desarrollo del trabajo, se lleva a cabo la adquisición del conocimiento necesario para la selección de las variables influyentes, la cual servirá posteriormente para la realización de filtros de información y determinación de variables de entrada.

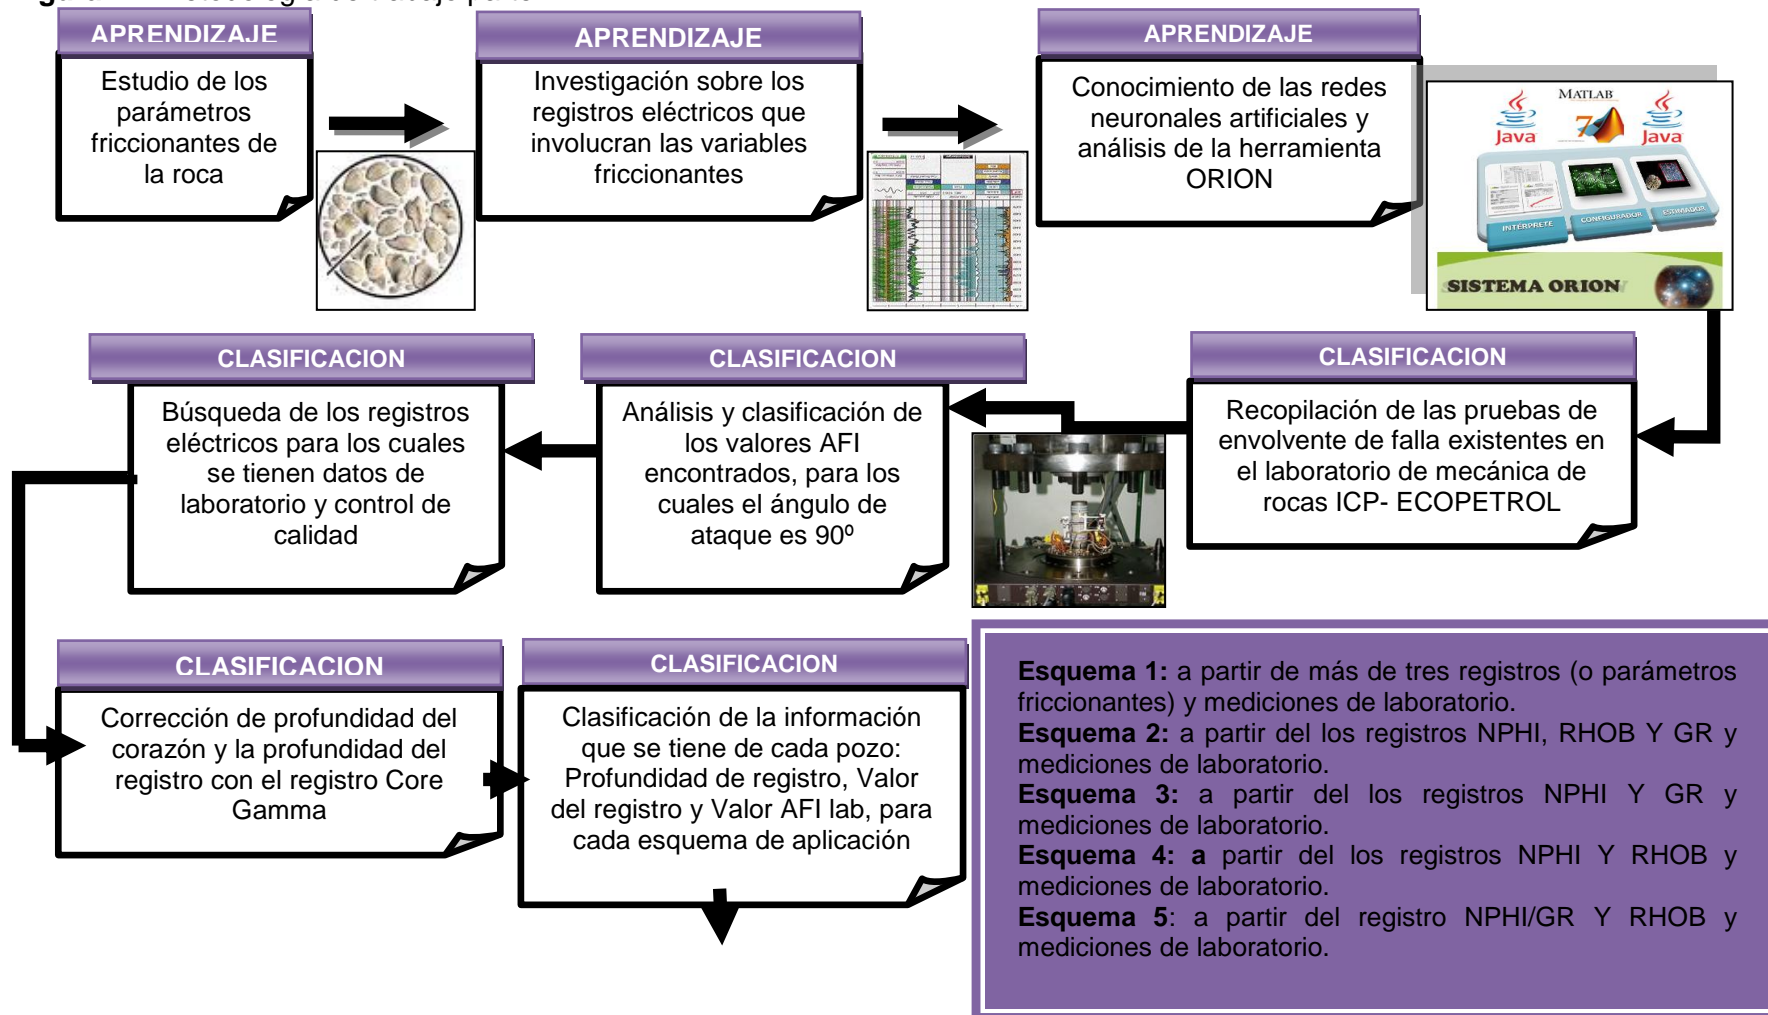
Pasos:

1. Estudio de los parámetros friccionantes de la roca.
2. Investigación sobre los registros eléctricos que involucran las variables friccionantes.
3. Conocimiento de las redes neuronales artificiales y análisis de la herramienta a utilizar, en este caso: ORION™.

13.2 ETAPA DE CLASIFICACIÓN

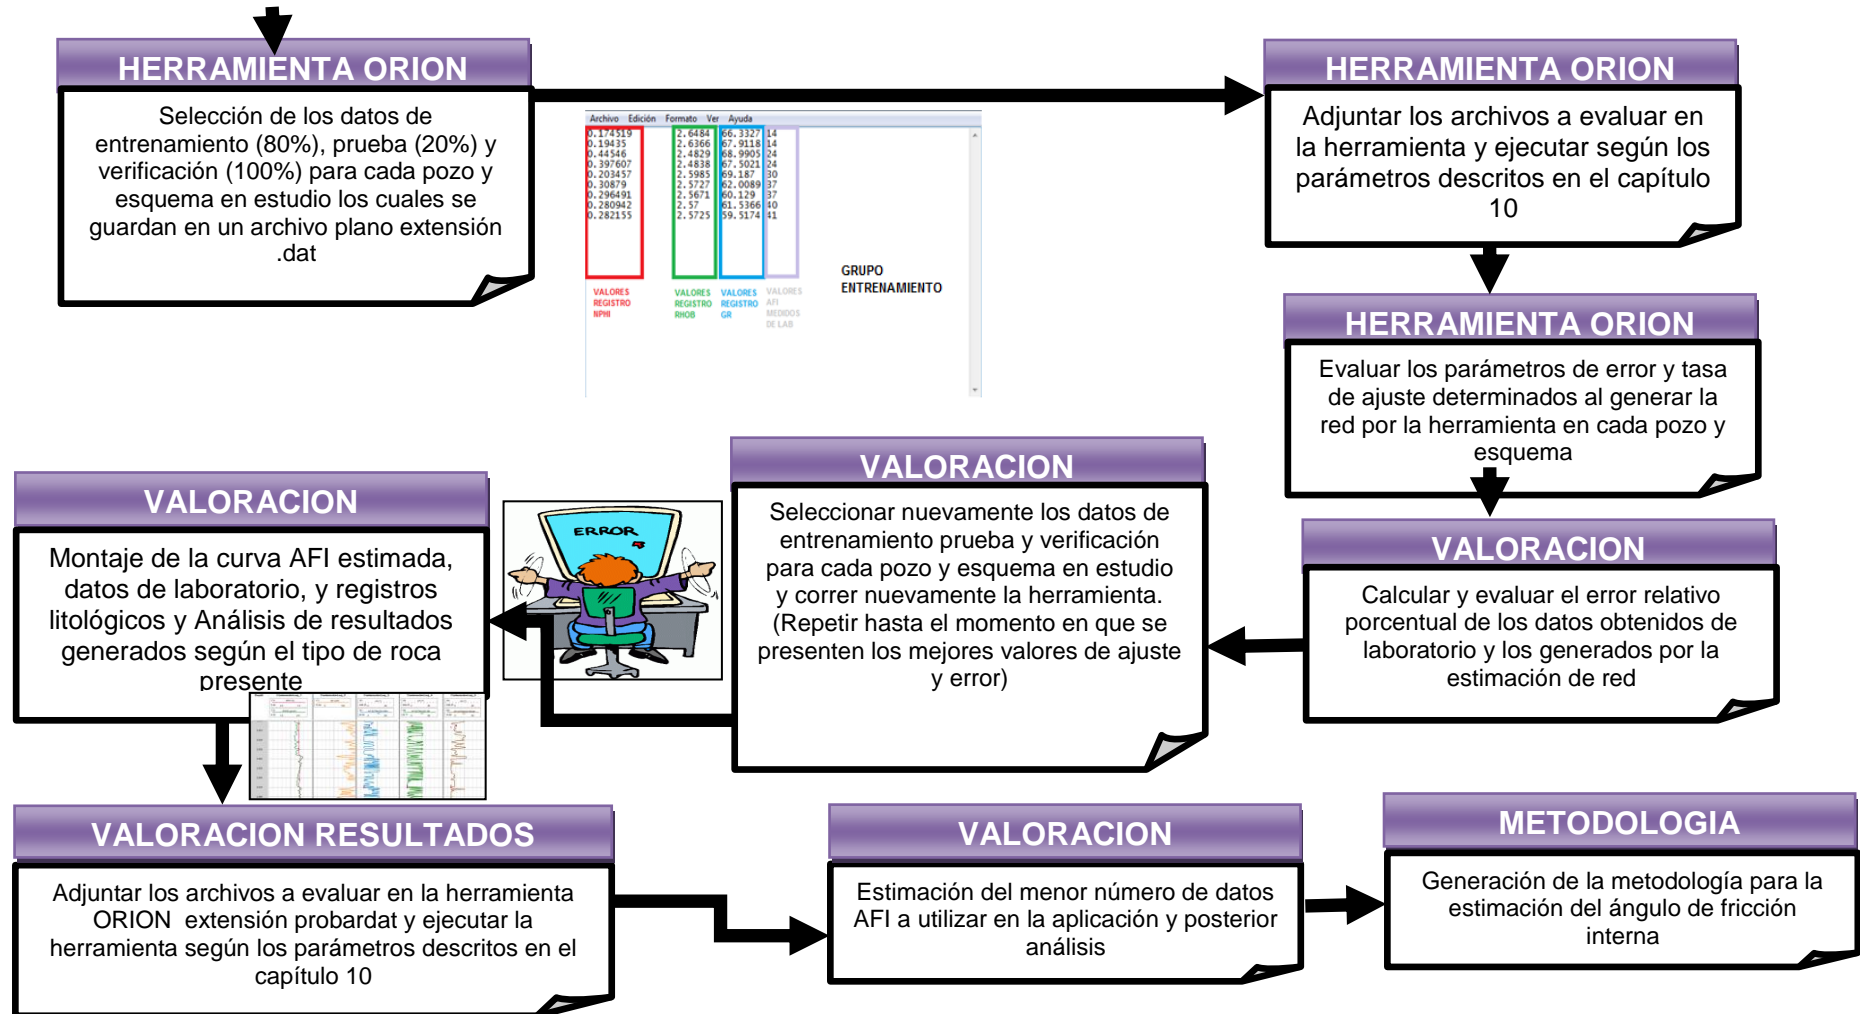
En esta etapa es importante disponer del tiempo necesario para la recolección y análisis adecuado de los datos que se van a utilizar, debido a que un mal manejo puede generar errores y malas estimaciones al momento de la aplicación y no se coincidirá con los resultados esperados.

Figura 47. Metodología de trabajo parte 1.



Fuente. El autor

Figura 48. Metodología de trabajo parte 2.



Fuente. El autor

Pasos:

1. Recopilación de las pruebas de envolvente de falla debidamente interpretadas, en el laboratorio de mecánica de rocas ICP-ECOPEPETROL.
2. Análisis y clasificación de los valores AFI encontrados.
3. Búsqueda de los registros eléctricos y control de calidad de los mismos. Para lo cual se debe inspeccionar, recorrer y correlacionar el registro trazo a trazo, con el fin de identificar picos anómalos o lecturas erróneas, corregirlos y suavizar las curvas.
4. Corrección de profundidad del corazón y la profundidad del registro con el registro Core Gamma. Mediante la alineación de los picos y valles de los perfiles, adicionándose o se restándose el desfase a las profundidades de los datos AFI de laboratorio según sea necesario.
5. Selección de un pozo que contenga una cantidad alta de datos en la zona de aplicación al estudio, para el cual luego se clasifica la información recolectada y se ordena para la aplicación de diferentes esquemas, con el fin de validar cual se ajusta mejor, y por la o las cual (es) será finalmente implementada en el total de los pozos.

Los registros clasificados como aplicables en la metodología son: los registros de porosidad (NPHI y DT) que miden la porosidad de la roca, el registro Gamma Ray (GR) que mide el contenido de arcilla y granulometría que presenta un tipo roca, el registro de Densidad (RHOB) que mide la porosidad y muestra el contenido o índice de vacíos de la roca y finalmente el registro resistivo que permite evidenciar el contenido de fluido en la roca, siendo finalmente los factores influenciadores para la estimación del ángulo de fricción interna utilizados en esta aplicación.

- ◆ Esquema 1: Estimación AFI por pozo, a partir de más de tres registros (o parámetros friccionantes).
- ◆ Esquema 2: a partir de los registros NPHI, DT, GR y RHOB
- ◆ Esquema 3: a partir de los registros NPHI, RHOB Y GR.
- ◆ Esquema 4: a partir de los registros NPHI Y GR.
- ◆ Esquema 5: a partir de los registros NPHI Y RHOB.

13.3 ETAPA DE ESTIMACIÓN DE REDES

En esta etapa se aplican los criterios seleccionados por los autores de la herramienta ORION™, con el fin de encontrar el mejor tipo de red entre muchas que valida el algoritmo genético en la estimación AFI a partir de los datos de laboratorio y registros de pozo introducidos para el entrenamiento.

Pasos:

1. Selección de los datos según los autores de la herramienta para: el entrenamiento (80%), prueba (20%) y verificación (100%) para cada esquema en estudio, los cuales deben ser guardados en un archivo plano extensión .dat.
2. Adjuntar los archivos a evaluar en la herramienta y ejecutar según los parámetros descritos en el Capítulo 10.
3. Evaluar los parámetros de error y tasa de ajuste determinados al generar la red por la herramienta en el pozo y esquema de aplicación.

13.4 ETAPA DE VALIDACIÓN DE LAS REDES

Esta etapa se genera al final los resultados valorativos que permiten predecir de manera confiable a partir de la herramienta seleccionada la metodología, por lo cual es importante seguir paso a paso cada uno de los puntos y al final generar un análisis minucioso.

Pasos:

1. Seleccionar nuevamente los datos de entrenamiento prueba y verificación para el esquema en estudio y correr la herramienta. (Repetir hasta el momento en que se presenten los mejores valores de ajuste y error).

En este trabajo se mostraran solo las mejores estimaciones de red que genera la herramienta que presenten una buena tasa de ajuste, una estimación de errores bajos y un número de errores mínimo. Para lo cual se variaron los datos utilizados en la data (datos de entrenamiento, prueba y verificación) y se muestra finalmente la mejor estimación.

2. Cálculo y evaluación del error relativo porcentual de los datos obtenidos de laboratorio y los generados por la estimación de red, con el fin de evaluar la certitud de las estimaciones generadas.

13.5 ETAPA DE ANÁLISIS DE LOS RESULTADOS

Para la valoración de la estimación de la red en conjunto con la propiedad, se debe aplicar el conocimiento adquirido en la etapa de aprendizaje, valorando los rangos de aplicabilidad para cada tipo de roca y el análisis en el cambio de litología que presenta los registros aplicados, con el fin de poder generar una respuesta confiable, en rangos para los cuales no se tienen mediciones comparativas.

1. Adjuntar los archivos a evaluar en la herramienta ORION extensión probardat y ejecutar la herramienta, teniendo en cuenta el orden de las variables utilizadas en el entrenamiento, prueba y verificación de la red.
2. Realizar por medio de un software de registros el montaje de las curvas AFI estimado, datos de laboratorio, y registros litológicos, analizando la propiedad y el ajuste de los datos en toda la sección de aplicación.

13.6 ETAPA DE APLICACIÓN

En donde se emplean las etapas de: clasificación de la información, aplicación de la herramienta ORION™, validación de los resultados y análisis de los resultados por tipo de roca presente a la totalidad de los pozos y esquemas definidos como aplicativos.

13.7 ETAPA DE VALIDACIÓN

Debido a que las diferentes formaciones o zonas que componen una cuenca, presentan características petrofísicas similares, la etapa de validación consiste en seleccionar un pozo cercano a uno de los pozos utilizados en el análisis y determinación del AFI, correr la red para dicho pozo y comparar la respuesta mineralógica que se espera, con el fin de validar la aplicabilidad y definir posteriormente la metodología.

13.8 ETAPA DE GENERACIÓN DE LA METODOLOGÍA

Finalmente se genera las variables aplicativos en la metodología y cada uno de los pasos a seguir en la estimación.

14 APLICACIÓN DEL ESQUEMA DE TRABAJO

14.1 ESTIMACIÓN DE REDES PARA LA VALIDACIÓN DE LOS ESQUEMAS EN EL POZO A1

A partir de la etapa de aprendizaje, se selecciono el pozo A1, como validador de los diferentes esquemas planteados, debido a que contiene la mayoría de los registros eléctricos involucrados y un gran número de pruebas de laboratorio debidamente interpretadas.

Se determino el ángulo de ataque a partir del mapa estratigráfico de la zona y la inclinación del pozo, para lo cual forman un ángulo de 90.

Luego se procedió a generar el control de calidad de los registros, a partir de reportes de perforación, el registro Caliper y tendencia mineralógica descrita de núcleos. Para lo cual finalmente, se correlaciono la profundidad del registro con la profundidad de las muestras evaluadas en laboratorio, obteniéndose la selección mostrada en la **Tabla 8**:

Tabla 8. Datos seleccionados para el entrenamiento de las Redes Neuronales en el Pozo A1.

DEPTH	DT	GR	Neutrón	RHOB	RESISTIVO	AFI
13187	89.0467	62.0089	0.244629	2.5727	4.4584	37
13187.5	83.907	60.129	0.268968	2.5671	4.4898	37
13188	83.7471	61.5366	0.282342	2.57	4.4738	40
13188.5	83.7215	59.5174	0.269007	2.5725	4.279	41
13195	78.8213	68.9905	0.349839	2.4829	3.0009	24
13195.5	83.1792	67.5021	0.335386	2.4838	3.1569	24
13213	73.2565	66.3327	0.205038	2.6484	6.5364	14
13213.5	74.5979	66.7757	0.206869	2.6356	6.4412	14
13214	77.3211	67.9118	0.231935	2.6366	6.4459	30
13214.5	77.1174	69.187	0.364344	2.5985	6.5318	30

Fuente. El autor

14.1.1 ESQUEMA 1

Se recuerda que el esquema 1 tomara en cuenta los registros de pozo: Porosidad y Sónico (NPHI y DT) que miden la porosidad de la roca, el registro Gamma Ray (GR) que mide el contenido de arcilla y granulometría que presenta un tipo roca, el registro de Densidad (RHOB) que mide la porosidad y muestra el contenido o índice de vacíos de la roca y finalmente el registro resistivo que permite evidenciar el contenido de fluido en la roca, factores influyentes como se describió en la determinación AFI.

14.1.2 Pasos en la estimación de las redes:

Se realizaron dos corridas con diferentes distribuciones del grupo de datos utilizados para el entrenamiento prueba y verificación hasta que finalmente se obtuvo una tasa de ajuste del 100% para lo que también disminuyeron los porcentajes de error, llevando a no entrenar un nuevo grupo y seleccionar finalmente la red.

El primer grupo de los datos (Ver **Tabla 9**) para el entrenamiento y verificación, se tomo teniendo en cuenta una variabilidad en las tendencias expuestas a diferentes profundidades del ángulo de fricción interna de la roca, seleccionándose para verificación dos datos: el de 40 grados a una profundidad de 13181 ft y de 30 grados con una profundidad de 13201 ft con el fin de tener dos datos intermedios para la valoración según los rangos vistos en la totalidad del pozo, definiéndose:


Tabla 9. Datos seleccionados para el primer grupo de entrenamiento de las Redes Neuronales en la herramienta ORION™ para el Pozo A1 (e=entrenamiento, v=verificación).

Dato	DEPTH	DT	GR	NPHI	RHOB	ILD	AFI
e	13173	74.5977	28.97159	0.2188	2.131900	7.106400	37
e	13174	78.08540	31.96369	0.232948	2.193200	7.898900	37
v	13174.5	75.67079	36.89849	0.244840	2.209700	7.574900	41
e	13175	77.4823	39.26810	0.2538	2.240499	7.246399	40
e	13181	86.44270	88.08300	0.355946	2.471699	4.05590	24
e	13181.5	87.89689	75.15789	0.341939	2.296900	3.833899	24
e	13196	74.53739	64.40940	0.325197	2.470999	3.397099	14
e	13196.5	67.18450	57.24560	0.2799	2.414999	3.782799	14
e	13201	75.71420	41.76419	0.175803	2.613300	7.972000	30
v	13201.5	75.5729	45.32180	0.1963	2.628200	7.309000	30

Fuente. El autor

Para lo cual se presento la configuración que se muestra la **Figura 49** y la Tabla 10. **Configuración de la red neuronal para el primer grupo de entrenamiento en el pozo A1 - Esquema 1.**, con las 5 variables de datos utilizadas como entrada, 3 capas ocultas, la primera con 4 neuronas, la segunda con 6 y la tercera con 3, para lo que se presento como muestra la tabla 10 una tasa de ajuste de los datos estimados por la red y los reales del 90%.

Figura 49. Configuración de la red neuronal para el esquema 1 a partir del primer grupo de datos en el pozo A1.



Fuente. El Autor

Tabla 10. Configuración de la red neuronal para el primer grupo de entrenamiento en el pozo A1 - Esquema 1.

	Pozo A1
Configuración de capas ocultas	4,6,3
Numero de errores	1
Peor error	0.011
Error promedio (%)	0.55
Tasa de ajuste (%)	90

Fuente. El autor

El segundo grupo se elijo teniendo en cuenta la configuración de datos que pudiera discriminar de una mejor forma cada uno de los rangos de variación que permitiera aumentar la tasa de ajuste y reducir el porcentaje de error. En búsqueda a esto se selecciono el grupo que se muestran en la **Tabla 11**, el cual contempla dos datos de verificación: 37 y 40 grados, para los cuales se tienen datos iguales y superiores suficientes que cubren la variación mineralógica permitiendo tener un rango de aprendizaje amplio y no como el anterior que era el de 40 y 30 que aunque eran valores intermedios, el dato

próximo de 30 es muy lejano y varía la tendencia de forma abrupta para lo cual la red no puede discriminar establemente.

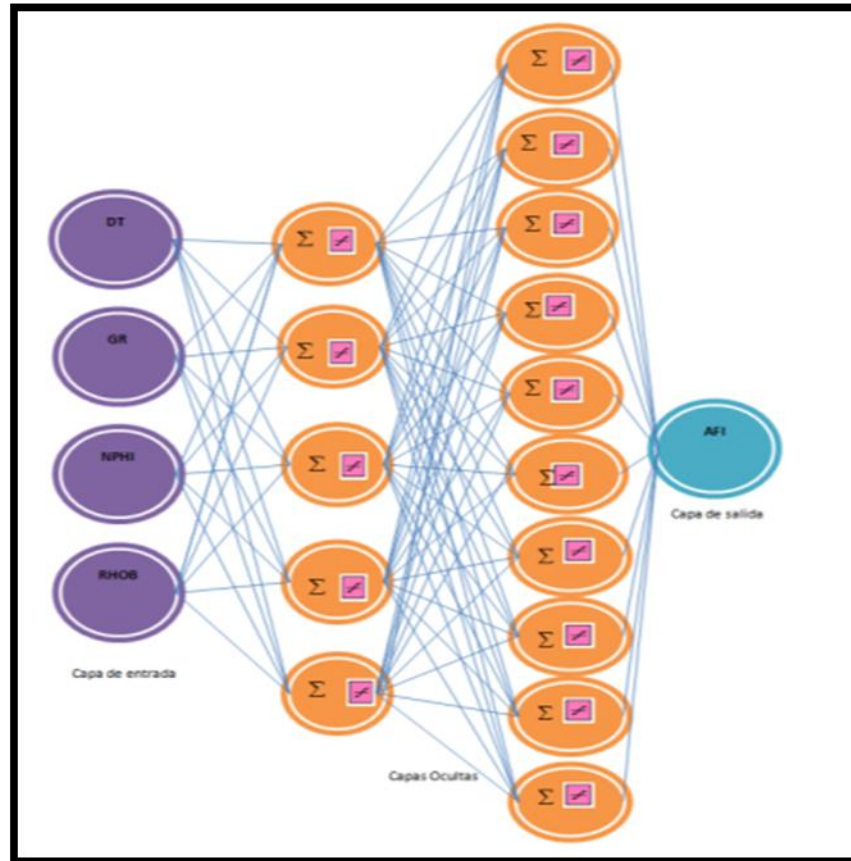
Tabla 11. Datos seleccionados para el segundo grupo de entrenamiento de las Redes Neuronales en la herramienta ORION™ para el Pozo A1 (e=entrenamiento, v=verificación).

Dato	DEPTH	DT	GR	NPHI	RHOB	ILD	AFI
v	13187	89.0467	62.0089	0.244629	2.5727	4.4584	37
e	13187.5	83.907	60.129	0.268968	2.5671	4.4898	37
v	13188	83.7471	61.5366	0.282342	2.57	4.4738	40
e	13188.5	83.7215	59.5174	0.269007	2.5725	4.279	41
e	13195	78.8213	68.9905	0.349839	2.4829	3.0009	24
e	13195.5	83.1792	67.5021	0.335386	2.4838	3.1569	24
e	13213	73.2565	66.3327	0.205038	2.6484	6.5364	14
e	13213.5	74.5979	66.7757	0.206869	2.6356	6.4412	14
e	13214	77.3211	67.9118	0.231935	2.6366	6.4459	30
e	13214.5	77.1174	69.187	0.364344	2.5985	6.5318	30

Fuente. El autor

La herramienta al final arroja la configuración de la red que mejor ajuste brinda el AG en base a 2 capas ocultas, la primera con 5 neuronas y la segunda con 10 (Ver **Figura 50**) con una tasa de ajuste del 100% como se muestra en la **Tabla 12**:

Figura 50. Configuración de la red neuronal para el esquema 1 a partir del primer grupo de datos en el pozo A1.



Fuente. El autor

Tabla 12. Error relativo porcentual entre el AFI medido en laboratorio y el AFI estimado por la herramienta ORION™ para el pozo A1- Esquema 1.

	Pozo A1
Configuración de capas ocultas	5,10
Numero de errores	0
Peor error	0.006
Error promedio (%)	0.354
Tasa de ajuste (%)	100

Fuente. El autor

A partir entonces de la red seleccionada como se muestra en la **Tabla 13** se cálculo el error relativo porcentual de los datos medidos en laboratorio y los estimados por la red, con el fin de poder visualizar el acierto o no de los datos

calculados por la herramienta, para lo cual se visualizo un buen ajuste con un error relativo máximo de 1.13%.

Tabla 13. Error relativo porcentual entre el AFI medido en laboratorio y el AFI estimado por medio de RNA para el pozo A1- Esquema 1.

DEPTH	DT	GR	NPHI	RHOB	ILD	AFI	AFI Estimado	Error Relativo %
13187	89.0467	62.0089	0.244629	2.5727	4.4584	37	37.266	0.71891892
13187.5	83.907	60.129	0.268968	2.5671	4.4898	37	37.274	0.74054054
13188	83.7471	61.5366	0.282342	2.57	4.4738	40	39.547	1.1325
13188.5	83.7215	59.5174	0.269007	2.5725	4.279	41	40.903	0.23658537
13195	78.8213	68.9905	0.349839	2.4829	3.0009	24	24.04	0.16666667
13195.5	83.1792	67.5021	0.335386	2.4838	3.1569	24	24.037	0.15416667
13213	73.2565	66.3327	0.205038	2.6484	6.5364	14	14.125	0.89285714
13213.5	74.5979	66.7757	0.206869	2.6356	6.4412	14	14.115	0.82142857
13214	77.3211	67.9118	0.231935	2.6366	6.4459	30	29.818	0.60666667
13214.5	77.1174	69.187	0.364344	2.5985	6.5318	30	30.011	0.03666667

Fuente. El autor

Seguido se grafico en un software de registros los datos de laboratorio Vs curva de estimación y la flexión litológica de los registros presentes como se visualiza en la **Figura 51**.

En el primer track (izquierda) se encuentra el registro Caliper y diámetro de la broca, en el track 2 el registro Gamma Ray, en el Track 3 el registro NPHI, en el track 4 el registro RHOB, en el track 5 el registro DRHO, en el track 6 el registro DT, en el track 7 el registro ILD, en el track 8 el registro AFI lab y AFI estimado por la red y por ultimo en el track 9 la litología presente en la zona. El ángulo de fricción interna varia ante cualquier cambio litológico o flexión de las curvas, para lo cual se mantienen en valores superiores a 30 en arenas con bajo porcentaje de arcillas, alta resistividad, baja porosidad y densidades altas.


Los 800 ft que comprende la formación en estudio para el pozo A1, se encuentra compuesta principalmente por areniscas, shale y lodolitas. El análisis que se realizo acerca de la certitud que puede llegar a tener los resultados de las configuraciones, se baso principalmente en la tendencia prevista según el

tipo de roca presente. En las arenas (facie de color amarillo) se evidencia un comportamiento de medición superior a los 30 grados, lo que indicaría que se encuentra evaluando dicha litología. En las arcillas y lodolitas estos valores son inferiores debido a la poca resistencia mecánica que presentan para lo cual en shales (facie gris) y lodolitas (facie naranja) los valores de AFI se encuentran entre 15 y 25, indicando en algunos casos areniscas con mezclas de algunas de las arcillas mencionadas o porcentaje más puro de las mismas.

Aunque la evaluación de este tipo de resultados puede ser un poco tedioso, debido al desconocimiento preciso del tipo de roca presente, las evaluaciones de la estimación de las propiedades mecánicas se basan en el bosquejo general que presenta según la respuesta de los registros litológicos presentes, por lo cual se puede afirmar que la selección de este grupo de registros puede generar resultados confiables, sin embargo la refinación y nuevas valoraciones son aconsejables de hacer en estudios posteriores.

Esta buena valoración se debe principalmente a la cantidad de variables involucradas que afectan directamente la medición (envolviendo propiedades como porosidad, granulometría, compacidad, volumen de arcilla y compacidad) y la variación mineralogía que presentan los datos de laboratorio, los cuales permiten de manera facilitadora la obtención de buenos resultados.

Figura 51. Datos de laboratorio AFI vs curva de estimación AFI calculado en conjunto con los registros presentes para la estimación, en el pozo A1- Esquema 1.



Fuente. El autor

14.1.3 ESQUEMA 2

A partir de los registros de porosidad (NPHI y DT) que miden la porosidad de la roca, el registro Gamma Ray (GR) que mide el contenido de arcilla y granulometría que presenta un tipo roca y el registro de Densidad (RHOB) que

mide la porosidad y muestra el contenido o índice de vacíos de la roca, factores influenciadores para la estimación del ángulo de fricción interna, se implemento el siguiente esquema.

La estimación del tipo de red, se realizo en base a los datos seleccionados en el esquema 1 debido a los buenos resultados generados, mostrando del mismo modo para este caso errores bajos y un número de errores mínimo como se muestra en la **Tabla 14**.

Tabla 14. Configuración de la red neuronal para los pozos A1 - Esquema 2.

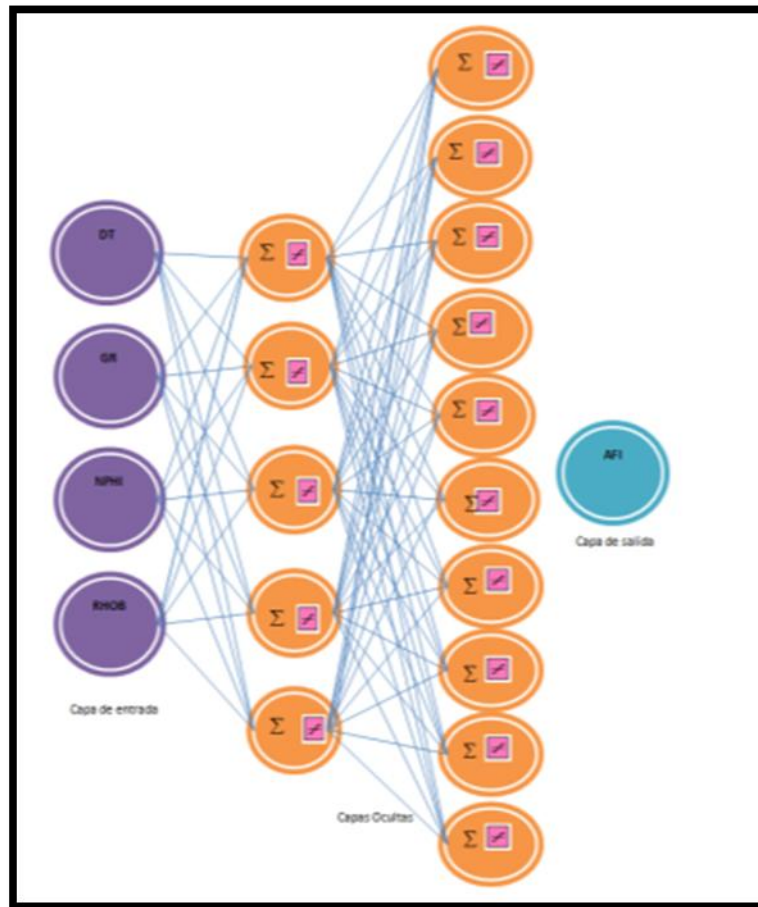
Pozo A1	
Configuración de capas ocultas	5,10
Numero de errores	0
Peor error	0.0036
Error promedio (%)	0.18
Tasa de ajuste (%)	100

Fuente. El autor

En la **Figura 52** se muestra la configuración de la red neuronal obtenida en la cual para los datos de las curvas de entrada, la mejor estimación de red que se obtuvo fue con dos capas ocultas la primera con 5 neuronas y la segunda con 10, con una tasa de ajuste del 100% entre sus datos de entrenamiento y verificación:

Seguido se calculo el error relativo porcentual entre los valores obtenidos por la red y los medidos por medio de pruebas de laboratorio, para lo cual se observa en la **Tabla 15** que el mayor porcentaje de error es de 0.107%.

Figura 52. Configuración de la red neuronal para el esquema 2 en el pozo A1.



Fuente. El autor


Tabla 15. Error relativo porcentual entre el AFI medido en laboratorio y el AFI estimado por medio de RNA para el pozo A1- Esquema 2.

DEPTH	DT	GR	NPHI	RHOB	AFI	AFI Estimado	Error Relativo %
13173	74.5977	28.97159	0.2188	2.131900	37	40.987	0.107
13174	78.08540	31.96369	0.232948	2.193200	37	36.977	0.0006
13174.5	75.67079	36.89849	0.244840	2.209700	41	40.947	0.001
13175	77.4823	39.26810	0.2538	2.240499	40	39.72	0.007
13181	86.44270	88.08300	0.355946	2.471699	24	24.193	0.008
13181.5	87.89689	75.15789	0.341939	2.296900	24	24.135	0.005
13196	74.53739	64.40940	0.325197	2.470999	14	14.015	0.001
13196.5	67.18450	57.24560	0.2799	2.414999	14	14.039	0.002
13201	75.71420	41.76419	0.175803	2.613300	30	29.948	0.001
13201.5	75.5729	45.32180	0.1963	2.628200	30	29.947	0.001

Fuente. El autor

En la **Figura 53** se muestran los datos de laboratorio vs curva de estimación y la flexión litológica de los registros presentes.

Figura 53. Datos de laboratorio AFI vs curva de estimación AFI calculado en conjunto con los registros presentes para la estimación, en el pozo A1 Esquema 2.



Fuente. El autor

La respuesta esperada por el tipo de litología presente, muestra evaluaciones similares a las estimadas en la curva con un mayor número de registros, resaltando que aunque no se tomaron en cuenta todas las variables de influencia AFI, una buena selección y refinación de los registros genera del mismo modo resultados confiables a lo que esperaríamos tener según el tipo de roca presente.

14.1.4 ESQUEMA 3


La valoración en este esquema se hizo a partir de el registro de porosidad (NPHI) que miden la porosidad de la roca, el registro Gamma Ray (GR) que mide el contenido de arcilla y granulometría que presenta un tipo roca y el registro de Densidad (RHOB) que mide la porosidad y muestra el contenido o índice de vacíos de la roca.

La estimación del mejor tipo de red, se realizo de igual forma en base a la selección descrita en el esquema 1, el cual presenta una buena tasa de ajuste, una estimación de errores bajos y un número de errores mínimo.

La configuración de la red se muestra en la **Figura 54**, para la cual se tienen 2 capas ocultas compuestas la primera de 10 neuronas, la segunda de 5 con una tasa de ajuste de 80% como se muestra en la

Tabla 16.

Figura 54. Configuración de la red neuronal para el esquema 3 en el pozo A1.



Fuente. El autor

Tabla 16. Configuración de la red neuronal para el pozo A1- Esquema 3.

Pozo A1	
Configuración de capas ocultas	5,8,10,9
Numero de errores	0
Peor error	0.007
Error promedio (%)	2.17
Tasa de ajuste (%)	80

Fuente. El autor

Seguido se calculo el error relativo porcentual (Ver **Tabla 17**) entre los valores obtenidos por la red y los medidos por medio de pruebas de laboratorio, para lo cual se observa en la tabla 17 el mayor porcentaje de error es de 0.018%.


Tabla 17. Error relativo porcentual entre el AFI medido en laboratorio y el AFI estimado por medio de RNA para el pozo A1- Esquema 3.

DEPTH	GR	NPHI	RHOB	AFI	AFI Estimado	Error Relativo %
13173	28.97159	0.2188	2.131900	37	37.148	0.004
13174	31.96369	0.232948	2.193200	37	37.177	0.004783
13174.5	36.89849	0.244840	2.209700	41	40.249	0.018317
13175	39.26810	0.2538	2.240499	40	40.388	0.0097
13181	88.08300	0.355946	2.471699	24	24.059	0.002458
13181.5	75.15789	0.341939	2.296900	24	23.807	0.008041
13196	64.40940	0.325197	2.470999	14	14.019	0.001357
13196.5	57.24560	0.2799	2.414999	14	14.08	0.005714
13201	41.76419	0.175803	2.613300	30	30.094	0.003133
13201.5	45.32180	0.1963	2.628200	30	30.115	0.003833

Fuente. El autor

Finalmente los datos de laboratorio vs curva de estimación y la flexión litológica de los registros presentes, se refleja en la **Figura 55**.

Figura 55. Datos de laboratorio AFI vs curva de estimación AFI calculado en conjunto con los registros presentes para la estimación, en el pozo A1 Esquema 3.



Fuente. El autor

La respuesta esperada por el tipo de litología presente muestra buenos ajustes, sin embargo con flexiones menos suavizadas que las arrojadas anteriormente.

Lo anterior indica que puede ser aplicado teniendo en cuenta la diferencia en la atenuación de las curvas.

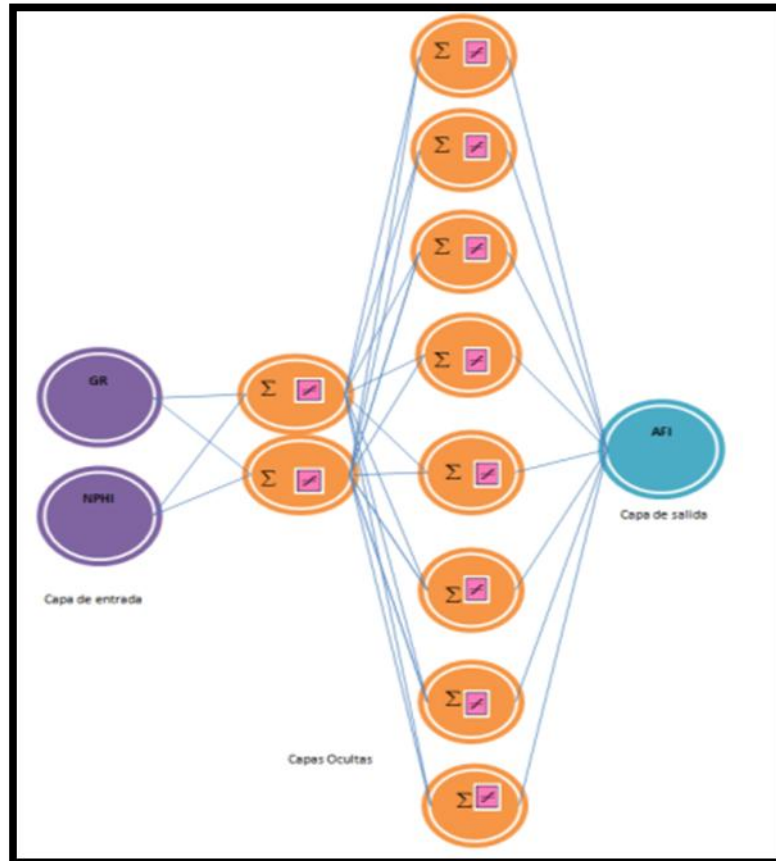
14.1.5 ESQUEMA 4

En este esquema se tienen en cuenta solo dos registros de pozo NPHI y GR, con el fin de discriminar mas el numero de curvas a utilizar a partir de dos propiedades fundamentales en la estimación AFI.

La configuración del tipo de red para este esquema se selecciono en base a los esquemas anteriores, definiéndose entonces la red que se ve en **Figura 56** en donde se compone de 2 capas ocultas la primera conformada por 2 neuronas y

la segunda por 8, a lo que presenta una tasa de ajuste entre los datos de 90% (Ver **Tabla 18**).

Figura 56. Configuración de la red neuronal para el esquema 4 en el pozo A1.



Fuente. El autor

Tabla 18. Configuración de la red neuronal para el pozo A1- Esquema 4.

	Pozo A1
Configuración de capas ocultas	2,8
Numero de errores	1
Peor error	0.02
Error promedio (%)	0.54
Tasa de ajuste (%)	90

Fuente. El autor

El máximo error relativo porcentual entre los valores obtenidos por la red y los medidos por medio de pruebas de laboratorio es de 0.023% como se muestra en la **Tabla 19**.


Tabla 19. Error relativo porcentual entre el AFI medido en laboratorio y el AFI estimado para el pozo A1- Esquema 4.

DEPTH	GR	NPHI	AFI	AFI Estimado	Error Relativo %
13187	28.9715996	0.218835	37	37.066	0.00178378
13187.5	31.9636993	0.23294801	37	37.318	0.00859459
13188	36.8984985	0.24484099	40	40.039	0.02343902
13188.5	39.2681007	0.253851	41	40.353	0.008825
13195	88.0830002	0.35594699	24	24.006	0.00025
13195.5	75.1578979	0.34193999	24	23.981	0.00079167
13213	64.4094009	0.32519701	14	14.215	0.01535714
13213.5	57.2456017	0.279946	14	14.117	0.00835714
13214	41.7641983	0.17580301	30	30.011	0.00036667
13214.5	45.3218002	0.196328	30	29.979	0.0007

Fuente. El autor

Los datos de laboratorio vs curva de estimación y la flexión litológica de los registros presentes se muestran en la **Figura 57**.

Figura 57. Datos de laboratorio AFI vs curva de estimación AFI calculada por la red en conjunto con los registros presentes para la estimación, en el pozo A1- Esquema 4.



Fuente. El autor

Las apreciaciones generadas a partir de solo los registros eléctricos Porosidad y Gamma Ray, presentaron errores relativos bajos, sin embargo se puede evidenciar que la curva de valoración no se ajusta a la mineralogía de la zona.

Lo que se puede analizar al respecto es que en la estimación de la red esta se encuentra muy influenciada por el registro porosidad, ya que maneja una similitud en la tendencia, para lo cual por ejemplo a bajas porosidades sin importar el contenido de arcilla el AFI se encuentra por encima de los 30 grados y en arcillolitas cuando su valor debería ser bajo aunque presente una porosidad intermedia, la estimación genera resultados superiores a 30 evidenciando arenas cuando realmente no se encuentran.

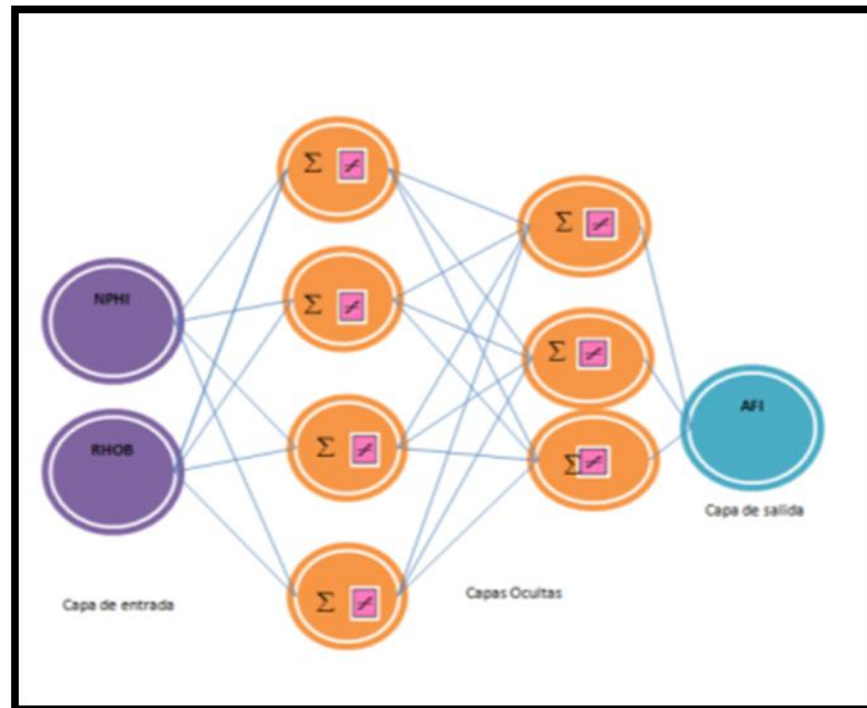
El esquema 4 no será tomado en cuenta como valedero, sin embargo se recomienda su aplicación bajo otras herramientas o tipos de inteligencia artificial que puedan llegar a mejorar los resultados.

14.1.6 ESQUEMA 5

La última estimación se realizó en base a los registros porosidad NPHI y densidad RHOB, teniendo en cuenta que ellos miden la porosidad de la roca, factor primordial en la estimación AFI.

El grupo de datos seleccionados para el entrenamiento se mantiene como en el caso de los esquemas anteriores, para lo cual en la **Figura 58** se muestra que la red se conforma de dos capas ocultas, la primera con 4 neuronas y la segunda con 3, para lo cual refleja una tasa de ajuste del 90% como se muestra en la **Tabla 20**.

Figura 58. Configuración de la red neuronal para el esquema 4 en el pozo A1.



Fuente. El autor

Tabla 20. Configuración de la red neuronal para el pozo A1- Esquema 5.

	Pozo A1
Configuración de capas ocultas	4, 3
Numero de errores	3
Peor error	0.10
Error promedio (%)	1.929
Tasa de ajuste (%)	70

Fuente. El autor

A partir de la configuración establecida, se procedió a calcular el error relativo porcentual entre los valores obtenidos por la red y los medidos por medio de pruebas de laboratorio, para lo cual se presentó un error máximo de 0.10% como se muestra en la **Tabla 21**.

Tabla 21. Error relativo porcentual entre el AFI medido en laboratorio y el AFI estimado para el pozo A1- Esquema 5.

DEPTH	NPHI	RHOB	AFI	AFI Estimado	Error Relativo %
13173	0.218835	2.13190007	37	33.237	0.1017027
13174	0.23294801	2.19320011	37	37.249	0.00672973
13174.5	0.24484099	2.20970011	41	40.604	0.00965854
13175	0.253851	2.24049997	40	40.937	0.023425
13181	0.35594699	2.47169995	24	24.118	0.00491667
13181.5	0.34193999	2.29690003	24	23.876	0.00516667
13196	0.32519701	2.47099996	14	14.477	0.03407143
13196.5	0.279946	2.41499996	14	14.006	0.00042857
13201	0.17580301	2.61330009	30	30.092	0.00306667
13201.5	0.196328	2.62820005	30	30.111	0.0037

Fuente. El autor


Los datos se laboratorio vs curva de estimación y la flexión litológica de los registros presentes, se encuentra en la **Figura 59**.

Las valoraciones generadas a partir de los registros eléctricos Porosidad y Densidad, generaron resultados poco confiables aunque con un porcentaje de error relativo entre los valores estimativos y de entrenamiento no superior a 0.1%.

Las falencias vistas se ven reflejadas en sectores que contienen arcillas, debido a que no se tiene en cuenta esta variable de manera representativa, tomando valores de AFI muy superiores a lo esperado con medios o altos contenidos.

Este esquema al igual que el anterior no son buenas alternativas de aplicación para la estimación AFI.

Figura 59. Datos de laboratorio AFI vs curva de estimación AFI calculada por la red en conjunto con los registros presentes para la estimación, en el pozo A1- Esquema 5.



Fuente. El autor

14.2 APLICACIÓN DE ESQUEMAS PARA EL POZO P5

Se selecciono el pozo P5, perteneciente a la cuenca del Catatumbo y que cuenta con 19 pruebas triaxiales debidamente interpretadas.

Se corrigieron y suavizaron en conjunto las curvas de los registros eléctricos obtenidos del pozo, para lo cual luego fue seleccionado el esquema tres de

aplicación a partir de los registros Porosidad, Densidad y Gamma Ray, debido a las curvas que se tienen del mismo.

Se evaluó el ángulo de ataque del pozo, por medio del mapa estructural de la zona y la desviación, para lo cual luego se dispuso a corregir la profundidad de los datos medidos en laboratorio con la profundidad de los registros eléctricos, por medio del registro Core Gamma y Gamma Ray.

Una vez seleccionadas las variables a utilizar, se clasificaron los datos para el entrenamiento, prueba y verificación de la red, para lo cual fue necesaria la corrida de 3 configuraciones de datos, obteniéndose finalmente con el menor porcentaje de error y mejor tasa de ajuste.

La selección de los datos fue un poco compleja, debido a que se cuenta con un numero grande de datos y variaciones AFI a diferencia del pozo A1, sin embargo el factor principal de selección se baso en escoger datos bajos, intermedios y altos para el entrenamiento que cubriera el rango litológico que presenta dicho valor y al mismo tiempo escoger en base a esto los datos de verificación que pudieran corroborar la certitud de la red.

En la **Tabla 22** se muestra los datos seleccionados que arrojaron los porcentajes de error mínimos y la mejor tasa de ajuste.

Tabla 22. Datos seleccionados para el primer grupo de entrenamiento de las Redes Neuronales en la herramienta ORION™ para el Pozo P4 (e=entrenamiento, v=verificación).

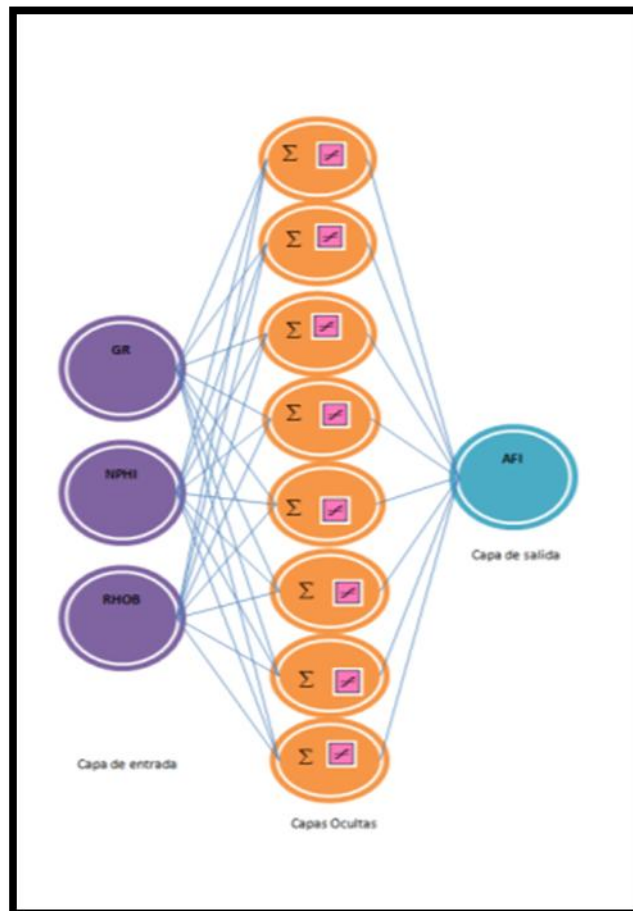
	MD (ft)	NPHI	RHOB	GR	AFI
e	607.5	0.1453	2.5674	109.1862	37
e	617.5	0.0082	2.6679	42.1398	37
v	618.5	0.0108	2.6642	39.9706	40
e	619.5	0.0115	2.6771	40.7417	40
e	1026.5	0.0669	2.6629	32.8847	40
e	1027.5	0.0649	2.6632	33.2782	41
e	1294.5	0.3222	2.5329	149.3243	24
e	1295.5	0.3394	2.5532	143.2078	24

	MD (ft)	NPHI	RHOB	GR	AFI
e	1296.5	0.2746	2.5718	123.0467	14
v	1358	0.309	2.5614	185.2752	14
e	1360.5	0.1594	2.6389	143.8585	14
v	1401.5	0.26	3.89	68.77	30
e	1402	0.27	3.87	77.07	30
e	1410.5	0.27	3.88	84.98	30
e	1587.5	0.1	2.67	62.61	15
e	1589	0.07	2.68	45.4	35
e	1589.5	0.07	2.68	48.28	35
v	1602.5	0.11	2.69	35.88	44
e	1604.5	0.08	2.7	56.69	44

Fuente. El autor

La configuración que arrojo la red se encuentra descrita en la **Figura 60** con una tasa de ajuste del 85% como muestra la **Tabla 23**.

Figura 60. Configuración de la red neuronal para el esquema 4 en el pozo P4



Fuente. El autor

Tabla 23. Configuración del mejor tipo de red generada por la herramienta Orion para el pozo P4

Numero de errores	3
Peor error	0.033759
Error promedio %	0.62075
Tasa de ajuste %	85
Configuración de las capas ocultas	8
	2 8
	2 8 8
	6
	5 10

Fuente. El autor

Luego se procedió a evaluar los porcentajes de error entre los datos medidos en laboratorio y los arrojados por la red, para lo cual se presento un buen ajuste con un porcentaje de error menor del 0.0337%, como se muestra en la **Tabla 24.**

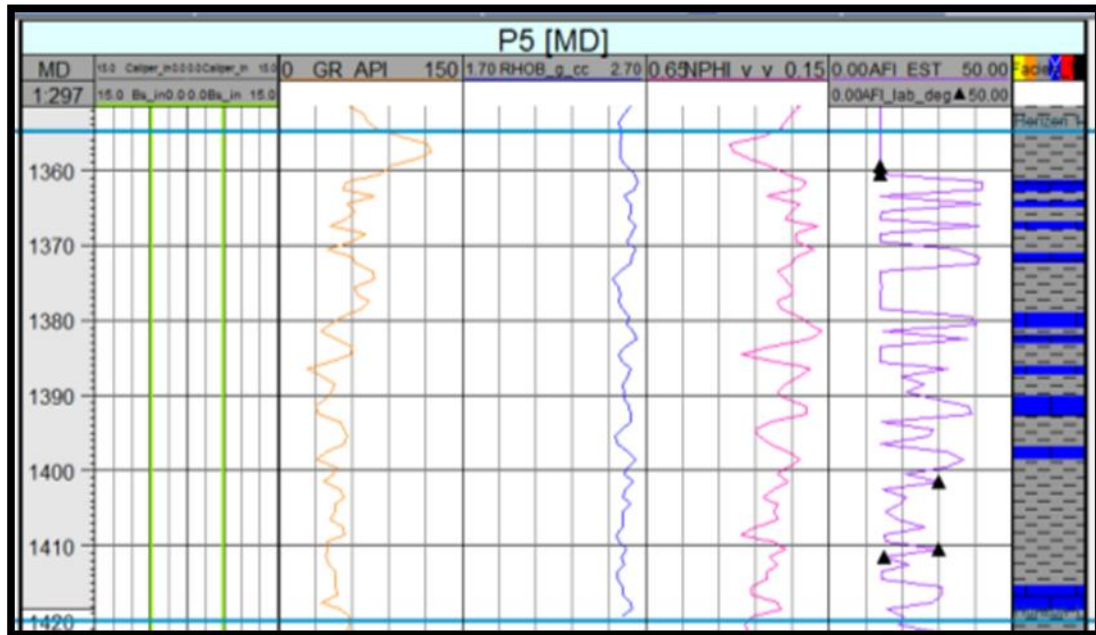
Tabla 24. Error relativo medido entre los datos de entrenamiento y los generados por la red para el pozo P5

MD (ft)	NPHI	RHOB	GR	AFI	AFI ESTIMADO	ERROR RELATIVO
607.5	0.1453	2.5674	109.1862	37	36.99	0.0002
617.5	0.0082	2.6679	42.1398	37	36.959	0.0011
618.5	0.0108	2.6642	39.9706	40	40.373	0.0093
619.5	0.0115	2.6771	40.7417	40	39.654	0.0086
1026.5	0.0669	2.6629	32.8847	40	40.815	0.0203
1027.5	0.0649	2.6632	33.2782	41	39.616	0.0337
1294.5	0.3222	2.5329	149.3243	24	24.007	0.0002
1295.5	0.3394	2.5532	143.2078	24	24.006	0.0002
1296.5	0.2746	2.5718	123.0467	14	14.061	0.0043
1356.5	0.309	2.5614	185.2752	14	14.006	0.0004
1358	0.1594	2.6389	143.8585	14	14.002	0.0001
1359.5	0.26	3.89	68.77	14	14.01	0.0007
1401.5	0.27	3.87	77.07	30	30.009	0.0003
1402	0.27	3.88	84.98	30	30.02	0.0006
1583	0.1	2.67	62.61	15	15.001	6.67E-05
1589	0.07	2.68	45.4	35	34.796	0.0058
1589.5	0.07	2.68	48.28	35	35.59	0.01685
1602.5	0.11	2.69	35.88	44	43.626	0.0085
1604.5	0.08	2.7	56.69	44	43.889	0.0025

Fuente. El autor

La visualización de la curva generada en toda la sección del pozo, presento la tendencia esperada según la mineralógica presente, flexionando en valores altos en minerales poco arcillosos y altos para las calizas y arenas contenidas, como se muestra en la **Figura 61**.

Figura 61. Visualización de la curva de estimación AFI para el pozo P5



Fuente. El autor

En el primer track (izquierda) se encuentra el registro Caliper y diámetro de la broca, en el track 2 el registro Gamma Ray, en el Track 3 el registro RHO B, en el track 3 el registro NPHI y por ultimo en el track 4 el registro AFI lab y AFI estimado por la red. El resultado refleja el ajuste que se presenta de los datos de laboratorio (rojos) y la curva que refleja las estimaciones en base al aprendizaje en el entrenamiento. La totalidad de los datos utilizados fueron 19 de los cuales 8 se reflejan en la zona de aplicación para el pozo P6. La litología presente muestra intercalaciones de calizas (visto en las facie azul, con valores de AFI superior a los 30 grados) y arcillas (predominantemente con un 90% de contenido en la zona, para lo cual se estiman valores de AFI bajos de 30).


14.3 APLICACIÓN DE ESQUEMAS PARA EL POZO C3

Teniendo en cuenta la validación descrita para el pozo A1, se planteo realizar la aplicación al pozo C3 del esquema 1 y 2.

Al organizar la información que se tiene de la zona, se descubre que este pozo no es viable para la estimación de las redes neuronales. Como se muestra en la **Figura 62** para cada formación existe una cantidad pequeña de datos con los que se puede realizar el entrenamiento de las redes, lo que no permitirá obtener buenos resultados, ya que los patrones de aprendizaje son pocos como también se visualiza en la página **159** en la selección del menor número de datos a utilizarse para el entrenamiento de la red neuronal según la herramienta ORION siguiendo la metodología planteada en esta tesis.

A nivel personal se realizaron los entrenamientos con la selección de dos formaciones las que se encuentran cercanas para poder mirar si podía ser aplicado pero los resultados fueron bastante malos, debido a la complejidad mineralógica de la zona.

Figura 62. Registros eléctricos del pozo C3.



Fuente. El autor


14.4 ESTIMACIÓN DEL MENOR NÚMERO DE DATOS AFI A UTILIZAR EN LA APLICACIÓN

Debido a que en cada uno de los pozos utilizados en este estudio, se tomaron entre 9 y 10 núcleos para la realización de las pruebas de laboratorio, las redes estimadas para la metodología se evaluaron teniendo en cuenta el set completo de datos. El principal factor para atender es que la mejor estimación se presenta en el momento en que se incluyan el mayor número de datos para el aprendizaje.

Sin embargo en búsqueda del menor número de pruebas a realizar para la estimación futura bajo esta metodología que presente un bajo número de

errores y una buena tasa de ajuste, se realizó el análisis, con el fin de determinar cuál sería el número mínimo de datos que se podrían llegar a utilizar, sin que variara el nivel de confianza aplicado al pozo A1, para lo que se encontró que el mínimo de datos recomendable es de 8 datos; 6 para entrenamiento y 2 para verificación. Mostrándose los siguientes resultados visualizados en la **Figura 63**, **Tabla 25** y **Tabla 26**:

Figura 63. Estimación del menor número de datos estimados para la aplicación de la metodología



Fuente. El autor

Tabla 25. Estimación del menor número de datos AFI para la aplicación de la metodología en el pozo A1.

AFI	Estimación AFI con 10 Datos	Estimación AFI con 9 Datos	Estimación AFI con 8 Datos	Estimación AFI con 7 Datos
14	14.097	14.001	14.005	14.081
14	14.097	14.005	14.039	14.143
14	14.087	14.063	14.092	14.262
24	24.159	23.977	23.846	24.001
24	24.033	23.976	24.041	23.97
30	39.955	29.995	30.127	29.902
37	36.697	37.139	37.418	37.087

AFI	Estimación AFI con 10 Datos	Estimación AFI con 9 Datos	Estimación AFI con 8 Datos	Estimación AFI con 7 Datos
37	36.914	37.245	37.204	40.831
40	49.945	40.278	40.085	38.42
41	40.929	40.019	40.703	40.842

Fuente. El autor

Tabla 26. Error relativo porcentual para la estimación del menor número de datos AFI para la aplicación de la metodología en el pozo A1.

Error Relativo % con 10 Datos	Error Relativo % con 9 Datos	Error Relativo % con 8 Datos	Error Relativo % con 7 Datos
0,56428571	0,00714286	0,03571429	0,57857143
0,69285714	0,03571429	0,27857143	102142857
0,62142857	0,45000000	0,65714286	187142857
0,66250000	0,09583333	0,64166667	0,00416667
0,13750000	0,10000000	0,17083333	0,12500000
0,15000000	0,01666667	0,42333333	0,32666667
0,81891892	0,37567568	112972973	0,23513514
0,23243243	0,66216216	0,55135135	103540541
0,13750000	0,69500000	0,21250000	3,95000000
0,17317073	239268293	0,72439024	0,38536585

Fuente. El autor

15 METODOLOGÍA PARA LA ESTIMACIÓN DEL ÁNGULO DE FRICCIÓN INTERNA

Finalmente como cumplimiento del objetivo principal del proyecto, A partir de las valoraciones presentadas en los pozos anteriores, se plantea una metodología de estimación AFI, la cual es aplicada al pozo P4, perteneciente a la cuenca del Catatumbo, con el fin de evaluar la viabilidad y éxito del trabajo:

1. Selección de la zona de interés para la realización del muestreo y posteriores pruebas de laboratorio.

En esta etapa es primordial considerar preferiblemente los intervalos para los cuales se refleja una variación mineralógica representativa, con el fin de obtener una discriminación de la propiedad y a partir de un mínimo de 8 muestras.

2. Verificar e inspeccionar los registros eléctricos disponibles para la zona en la que se desea aplicar la metodología.

En esta etapa, se debe no solo iniciar la búsqueda de los registros eléctricos influyentes en la estimación AFI, sino que también es primordial un proceso de control de calidad, en el cual el intérprete debe inspeccionar, recorrer y correlacionar el registro trazo a trazo, con el fin de identificar picos anómalos o lecturas erróneas, corregirlos y suavizar las curvas, para finalmente adicionar en el diagrama de aplicación.

3. Selección del conjunto de registros eléctricos a utilizar, según el esquema que se desee aplicar.
 - ◆ Esquema 1: a partir de más de tres registros (o parámetros friccionantes).

- ◆ Esquema 2: a partir de los registros de Porosidad, Densidad y Gamma Ray.
 - ◆ Esquema 3: a partir de los registros Porosidad, Densidad y Gamma Ray
4. Determinar la orientación del pozo con respecto a los planos de buzamiento, para la estimación del ángulo de ataque.
Debido a que el ángulo de ataque es un factor determinante en la estimación AFI, basado en la valoración que refleja la falla a lo largo de los planos de buzamiento más débiles, más conocidos como planos de debilidad, es importante antes de la aplicación de la metodología, tener en cuenta que solo puede ser aplicada para un ángulo de 90° , de lo contrario la respuesta sería errónea y por lo tanto la aplicación no sería válida.
 5. Corrección de la profundidad del corazón muestreado.
En esta etapa es indispensable la obtención del registro Core Gamma, con el fin de correlacionar la profundidad del núcleo utilizado en el muestreo con los registros de pozo.
De no poder corregir las profundidades, los resultados obtenidos pueden no ser confiables.
 6. Clasificación de la información que se tiene de cada pozo.
En esta etapa se debe tener en cuenta que debido a que normalmente se encuentra la información en archivos diferentes, uno el resultado del laboratorio y otra la medición del registro o propiedad, se debe proceder a integrar el valor del registro con la medición AFI, de forma tal que se obtenga finalmente en cada columna del archivo a evaluar: Profundidad, valor del registro y AFI medido.

7. Selección de los datos de entrenamiento, prueba y verificación, para cada pozo y esquema de aplicación.

Los datos utilizados para el entrenamiento deben clasificarse de tal forma que se deben seleccionar los rangos de variación de los registros para cada valor AFI, con el fin de examinar cuales son los valores máximos y mínimos presentados en el registro que cubran en totalidad cada valor.

Como mínimo el 80% de los datos totales muestreados para entrenamiento, para los datos utilizados como verificación serán los restantes que en porcentaje deben cumplir el 20% y los datos de prueba que comprenden el set de datos en su totalidad.

8. Adjuntar los archivos a evaluar y ejecutar según los parámetros descritos por la herramienta en estimación.

Para lo cual y como se había especificado en este trabajo se recomienda la utilización de la herramienta ORION.

9. Evaluar los criterios: Errores Generados y Tasa de Ajuste.

En esta etapa, primordial en la selección final de la red, es recomendable examinar el menor número errores y la mejor tasa de ajuste.

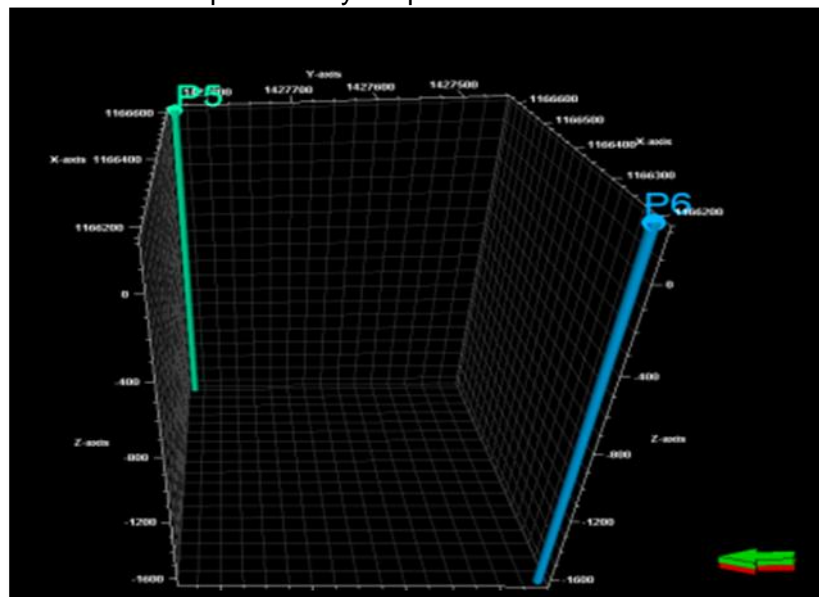
Recuerde que los resultados obtenidos dependen de la experiencia y conocimiento de los datos a trabajar por el configurador, para lo cual, se debe variar la distribución de los datos seleccionados en el paso 7, hasta obtener la mejor estimación.

10. A partir de la estimación final de la red, evaluar la propiedad en toda la sección del pozo y en los pozos cercanos en donde se presente la misma tendencia mineralógica, evaluando las restricciones planteadas como el ángulo de ataque y la validación de las curvas a utilizar, siendo corrida y correlacionada con los demás parámetros mecánicos y petrofísicos.

16 APLICACIÓN DE LA METODOLOGÍA


Para la aplicación de la metodología, fue seleccionado el pozo de entrenamiento P6, comparativo estructural y mineralógicamente al pozo entrenado P5 (Ver **Figura 64** y **Figura 65**).

Figura 64. Posición de los pozos P5 y P6 pertenecientes a la Cuenca del Catatumbo



Fuente. El autor

Figura 65. Visualización estructural de los pozos P5 y P6 pertenecientes a la Cuenca del Catatumbo




Fuente. Instituto Colombiano del Petróleo. ECOPETROL. SA

Se evaluó el ángulo de ataque del pozo, por medio del registro OFM del pozo y la desviación, arrojando 90° para las capas en la zona de aplicación. Luego se verificaron e inspeccionaron los registros eléctricos disponibles, seleccionándose por el número de curvas obtenidas el esquema 3.

Se adjuntaron los datos de los registros a valorar en la red ya entrenada, para lo cual se presentaron tendencias esperadas según la litología presente y similitud en la medición para cada formación o zona como se muestra en la **Figura 66**.

Figura 66. Visualización de la curva de estimación AFI para el pozo P6.



Fuente. El autor

En el primer track (izquierda) se encuentra el registro Caliper y diámetro de la broca, en el track 2 el registro Gamma Ray, en el Track 3 el registro RHO B, en el track 3 el registro NPHI y en el track 4 la curva que refleja las estimaciones en base al aprendizaje en el entrenamiento. La litología presenta intercalaciones de calizas y arcillas en gran parte, reflejándose de manera adecuada la valoración del AFI, para lo cual se evidenció que para rocas más

compactas y con mayor porosidad los valores son superiores a 30 y para los cuales con un alto contenido de arcilla los valores de AFI disminuyen hasta 20, tal como se esperaría en el pozo de entrenamiento y aplicación.

Lo anterior muestra la aplicabilidad de la metodología para la estimación del ángulo de fricción interna de la roca, en cualquier tipo de roca en la que el número de muestras sea representativa y el estado de los registros permitan perfilar características del mismo con una buena tasa de ajuste y una buena flexión mineralógica. Sin embargo hay que tener en cuenta las restricciones planteadas.

17 CONCLUSIONES

1. A partir de una revisión bibliográfica extensa desarrollada en pro de esta investigación, los parámetros considerados de mayor influencia en la determinación del ángulo de fricción interna se definieron de mayor a menor como: la compacidad, porosidad, granulometría, forma de las partículas, humedad, anisotropía, ángulo de ataque y volumen de arcilla.
2. Es posible la integración de métodos innovadores, que implementen nuevos conceptos como las “Redes Neuronales”, para la estimación de propiedades mecánicas, entre ellas el ángulo de fricción interna de la roca, a partir de un set mínimo de registros eléctricos; como de Porosidad, Gamma Ray y Densidad y datos de laboratorio, generando análisis precisos y resultados confiables, debido entre otros factores a su forma de operación y las ventajas que representa frente a otros tipos de inteligencia artificial.
3. Los resultados arrojados a partir del entrenamiento de las redes neuronales en el pozo A1 para los esquemas 1 que conllevan los registros: RES, DT, NPHI, GR, RHOB, 2: DT, NPHI, GR, RHOB y 3: NPHI, GR, RHOB, arrojaron estimaciones con una tasa de ajuste mínima de 80% y un porcentaje de error máximo de 2.17 con un error relativo porcentual medido entre los datos estimados y los de laboratorio máximo de 1.13%, lo cual permitió dar un aplicativo confiable en el desarrollo de la metodología planteada.
4. El pozo utilizado como entrenamiento P4 perteneciente a la cuenca del Catatumbo en el esquema 2, arrojó una tasa de ajuste de 85% y un porcentaje de error máximo de 0.62% para lo cual el error relativo estimado entre los datos arrojados y los utilizados en el entrenamiento

fue 0.03%, lo cual permitió el arreglo en el pozo aplicativo P5 con litología consistente superior a 35 para calizas e inferiores para arcillas.

5. Cuando existe una variación composicional y un gran set de datos distribuidos en gran parte de la sección del pozo a evaluar, la generación de los datos estimados por la utilización de redes neuronales, generan buenos resultados con tasas de ajuste que superan el 80% y errores relativos menores al 3%, con un mínimo de 8 pruebas triaxiales, siendo entonces considerada una buena herramienta de selección para la estimación del ángulo de fricción interna de la roca.

6. La herramienta ORION, generada para la estimación de redes neuronales en la evaluación de propiedades mecánicas, es un excelente facilitador para el desarrollo de nuevas metodologías que permitan el cálculo de propiedades, aumentando la simplicidad de la misma y disminuyendo los costos de estimación con un margen bueno de confianza.

RECOMENDACIONES

Se recomienda implementar esta metodología, refinando variables de aplicación, que al final permitan obtener resultados acertados con un menor número de variables, no solo para la estimación AFI si no para otras propiedades mecánicas.

NOMENCLATURA

- ◆ AFI: ángulo de fricción interna
- ◆ F: Factor de resistividad de la formación.
- ◆ R_O : Resistividad de la formación cuando la saturación de agua es el 100% en ohm-metro.
- ◆ R_W : Resistividad del agua de formación en ohm-metro.
- ◆ R_T : Resistividad total de la formación.
- ◆ A: Área, m^2 .
- ◆ I: Corriente eléctrica.
- ◆ V: Diferencia de potencial, volts.
- ◆ L: Longitud.
- ◆ \emptyset : Porosidad total, en fracción.
- ◆ S_{XO} : Saturación del agua.
- ◆ a: Radio de la esfera equipotencial.
- ◆ b: Punto de ubicación de la generación de corriente.
- ◆ R_{mf} : Resistividad del filtrado del lodo.
- ◆ R_{msfl} : Resistividad medida por el perfil de enfoque esférico.
- ◆ K: Permeabilidad de la roca.
- ◆ V_{ref} : Voltaje total de referencia.
- ◆ R_{mc} : Resistividad de la torta del lodo.

BIBLIOGRAFIA

- ◆ **ABDOU M. Prediction of Angle of Internal of Sand Using Grain-Size Distribution Curve.** Assiut University, Egypt.
- ◆ **BENDECK, J.** Octubre de 1982. **Perfiles eléctricos. Una herramienta para la evaluación de formaciones.** Santafé de Bogotá D.C.
- ◆ **BLICKLE T. AND THIELE L. A. Comparison of Selection Schemes Used in Genetic Algorithms. Technical Report 11, Computer Engineering and Comunnication Network Lab (TIK).** Zurich, Switzeland, 1995.
- ◆ **CÁCERES J Y VELLILA J. Análisis de los Efectos que Producen la Desviación de Pozo y el Buzamiento de las Capas en la Ventana de Lodo, una Aplicación en un Campo Colombiano.** Proyecto de grado presentado ante la Universidad Industrial de Santander (Bucaramanga, Colombia), como requisito para obtener el título de ingenieros de Petróleos. 2010.
- ◆ **CAMACHO JAVIER, REYES OSCAR Y NIETO ANDRÉS. Anisotropía de esfuerzos y resistencia al corte de las arenas. Ciencia e Ingeniería Neogranadina.** 2006.
- ◆ **CHANDONG CHANG ET AL. Empirical Relations Between Rock Strength and Physical Properties in Sedimentary Rocks.** Journal Of Petroleum Science And Engineering. 2006.
- ◆ **CHEN, X. C.P TAN AND C.M HABERFIELD. Wellbore Stability Analysis Guidelines for Practical Well Design.** SPE 20058. 1996.

- ◆ DR. PAUL GLOVER. **Petrophysics Course Notes**. 2006.

- ◆ E, FJAER. **Petroleum related rock mechanics**, 2nd ed. ELSEVIER. Pags 185 – 193. 1996.

- ◆ EARL, D Pile E.K. **Well Logging in Nontechnical Language**. BSME University of Tennessee. 2002.

- ◆ ECOPETROL. **Laboratorio de rocas. Instituto Colombiano del Petróleo**. ICP.

- ◆ ESCAMILLA R. **Modelamiento de Registros Sónico Y Densidad para la Elaboración de Modelos Geomecánicos del Área De Piedemonte**. Proyecto de grado presentado ante la Universidad Industrial de Santander (Bucaramanga, Colombia), como requisito para obtener el título de ingenieros de Petróleos. 2007.

- ◆ F.G.H. BLYTH AND M.H. DE FREITAS. **A geology for engineers, seventh edition**. ELSEVIER. Pags 187 - 197.1999.

- ◆ GALVIS, L; Y OCHOA, C. **Desarrollo de una herramienta software utilizando redes neuronales artificiales para estimar propiedades del comportamiento mecánico de arenas limpias**. Proyecto de grado presentado ante la Universidad Industrial de Santander (Bucaramanga, Colombia), como requisito para obtener el título de ingenieros de Sistemas. 2008.

- ◆ GARCÍA, M. **Determinación de la orientación y magnitud del esfuerzo máximo horizontal a partir del modelamiento de breakouts en la zona del piedemonte llanero colombiano**. Proyecto de grado presentado ante la Universidad Industrial de Santander (Bucaramanga,

- Colombia), como requisito para obtener el título de ingenieros de Petróleos. 2006.
- ◆ **GESTAL M., Introducción a los algoritmos genéticos, departamento de tecnologías de la información y las comunicaciones.** Universidad de Coruña. 1996.
 - ◆ **GOODMAN, RICHARD E. Introduction to rock mechanics.** 1980.
 - ◆ **H. DEMUTH, M. BEALE, M. HAGAN. Neural Network Toolbox™ User's Guide, Math Works.** pags 471-474. 2008.
 - ◆ **HOEK, E. & BRAY, JW. Rock Slope Engineering,** 3d Edition, London: Institute of Mining and Metallurgy.Pag 22. 1981.
 - ◆ **HOSSNE A. Resistencia Terramecánica en Función de la Humedad Edáfica de un Suelo Ultisol de Sabana del Estado Monagas, Venezuela.** Bioagro. 2003.
 - ◆ **ING. ANDRÉS MANTILLA Z Y RICARDO BUENO S. Seminario De Petrofísica E interpretación de Registros de Pozos.** Octubre de 2006.
 - ◆ **IZAURIETA F. Y SAAVEDRA C., Redes Neuronales Artificiales, Departamento de física.** Universidad de Concepción, Chile. 2003.
 - ◆ **J. FLORES, F. PORRAS, Determinación del patrón de flujo multifasico en tuberías de recolección de Petróleo Emulsionado, a Partir de los Datos Históricos de Producción Apoyado en una Aplicación con Redes Neuronales Artificiales.** Proyecto de grado presentado ante la Universidad Industrial de Santander (Bucaramanga, Colombia), como requisito para obtener el título de ingenieros de Petróleos. 2007.

- ◆ K. EDLMANN, J.M. SOMERVILLE at el. **Predicting Rock Mechanical Properties form Wireline Porosities**. 1988. SPE.
- ◆ L. LLANO, A. HOYOS, F. ARIAS, J. VELÁSQUEZ. **Comparación del Desempeño de Funciones de Activación En Redes Feedforward para Aproximar Funciones de Datos Con y sin Ruido**. Universidad Nacional de Colombia, Sede Medellín. 2007.
- ◆ LARRAÑAGA, PEDRO; INZA IÑAKI Y MOUJAHID ABDELMALIK. **Redes Neuronales. Departamento de Ciencias de la Computación Inteligente e Inteligencia Artificial**. Universidad del País Vasco-Euskal Herriko Unibertsitatea. 2000.
- ◆ MANTILLA, A Y BUENO R. **Seminario de Petrofísica e interpretación de Registros de Pozos**. Instituto Colombiano del Petróleo-ECOPETROL. Octubre de 2006.
- ◆ MENDEZ. E., Y MARIÑO. J. **Sistema Automático de entrenamiento de Redes Neuronales Artificiales Basados en el Ajuste Genético de Parámetros y Variación de Arquitectura**. Proyecto de grado presentado ante la Universidad Industrial de Santander (Bucaramanga, Colombia), como requisito para obtener el título de ingenieros de Sistemas.2008.
- ◆ MUÑOZ J. **Tutorial de Redes Neuronales Universidad Tecnológica de Pereira**. 2000.
- ◆ PALACIOS B, J y HERNANDEZ V, G. **Implementación de la teoría poroelástica en el análisis de la estabilidad de pozos mediante el desarrollo de una herramienta software aplicando el método de diferencias finitas**. Proyecto de grado presentado ante la Universidad

Industrial de Santander (Bucaramanga, Colombia), como requisito para obtener el título de ingenieros de Petróleos. 2008.

- ◆ PROF. DR. PÉRSIO LEISTER DE ALMEIDA BARROS. **Obras de contención manual técnico.** MACCAFERRI Maccaferri do Brasil.2006.
- ◆ R, Pemper et al. **A new pulsed neutron sonded for derivation of formation lithology and mineralogy.** SPE 102770. 2006.
- ◆ ROZO, A. **Desarrollo de una metodología para determinar el ángulo de fricción interna a partir del volumen de arcilla y la porosidad obtenidos de los registros eléctricos.** Proyecto de grado presentado ante la Universidad Industrial de Santander (Bucaramanga, Colombia), como requisito para obtener el título de ingenieros de Petróleos. 2008.
- ◆ S. WATANABE. **Pattern Recognition: Human and Mechanical.** Wiley, New York. 1985.
- ◆ SCHLUMBERGUER. 1989, **Cased Hole Log Interpretation Principles Applications.**
- ◆ SIERRA, O. **Fundamentals of well-log interpretation. Tomo 1. The acquisition of logging data.** Amsterdam. 1984.
- ◆ U. CHINCHILLA, G. PÉREZ. **Herramienta software para la identificación de sistemas dinámicos no lineales,** Proyecto de grado presentado ante la Universidad Industrial de Santander (Bucaramanga, Colombia), como requisito para obtener el título de ingenieros de Sistemas. 2007.
- ◆ V.W. PORTO, D.B. FOGEL, AND L.J. FOGEL. **Alternative Neural Network Training Methods, IEEE EXPERT,** 1995.

ANEXO A

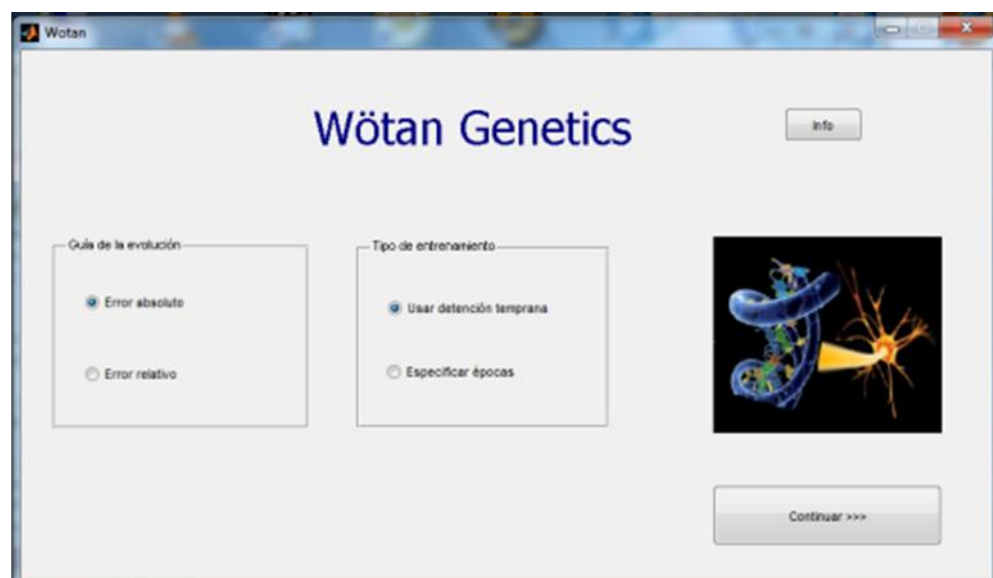
SISTEMA AUTOMÁTICO DE ENTRENAMIENTO DE REDES NEURONALES ARTIFICIALES BASADO EN EL AJUSTE GENÉTICO DE PARÁMETROS Y VARIACIÓN DE ARQUITECTURA

Descripción de la herramienta y su entorno grafico:

SELECCIÓN DEL TIPO DE ERROR Y TIPO DE ENTRENAMIENTO

Lo primero que inicia el programa es un menú de selección de los parámetros con los cuales se va a guiar la búsqueda, dependiendo de la selección de estos parámetros será el comportamiento del algoritmo genético y la forma de cargar los datos usada (**Fig. 1**).

Fig. 1. Ventana inicial del programa de redes Neuronales



Fuente. GALVIS, L; Y OCHOA, C. Desarrollo de una herramienta software utilizando redes neuronales artificiales para estimar propiedades del comportamiento mecánico de arenas limpias pertenecientes a una cuenca Colombiana. UIS. 2006

El tipo de error le indica al algoritmo genético la manera cómo va a evaluar el desempeño de una configuración, las opciones que se muestran para guiar la evolución son mediante el error absoluto o un error relativo porcentual. La selección del tipo de error a usar depende de la naturaleza de los datos de entrenamiento a usar depende de la naturaleza de los datos de entrenamiento a usar uno u otro. Se recomienda utilizar el error absoluto cuando alguna de las salidas de los datos de entrenamiento toma valores de cero puesto que se producirá un error en el cálculo del error relativo al dividirse por este valor.

Al usar el error relativo se debe tener en cuenta que el error tolerado que se escoge no es una diferencia real como en el absoluto sino que es un porcentaje de error permitido entre la salida obtenida y la obtenida.

Los tipos de entrenamiento se refieren a los tiempo en los que se va a realizar el entrenamiento de la red neuronal, para esto se tiene la opción de escoger entrenamiento con detención temprana lo que indica que se deben tener seleccionados los conjuntos de datos necesarios para este tipo de entrenamiento. Al especificar el número de épocas en las que se va a realizar el entrenamiento se debe tener un conocimiento sobre el comportamiento del problema para poder escoger un valor adecuado.

Esta opción es recomendada cuando se desean tomar mayor cantidad de datos para realizar en el entrenamiento de la red o cuando se tiene la noción sobre el número de épocas necesarias para realizar un buen entrenamiento.

CARGA DE DATOS

La carga de datos se realiza de acuerdo al tipo de entrenamiento escogido, si se decidió usar detención temprana se deben especificar los conjuntos de entrenamiento, verificación y prueba.

Se solicita el tipo de normalización que se quiere utilizar en las entradas y salidas respectivamente:

- ◆ Ninguna: No realiza ninguna acción sobre los datos.
- ◆ Sigmoial: Este tipo de normalización ajusta los datos en un rango entre cero y uno $[0,1]$.
- ◆ Tangente Hiperbólica: Este tipo de normalización ajusta los datos en un rango entre menos uno y uno $[-1,1]$.

La interfaz también solicita el número de entradas y de salidas. Después de llenar estos datos, se pueden cargar los archivos de datos en los que se encuentran agrupadas las entradas y salidas en sus valores originales.

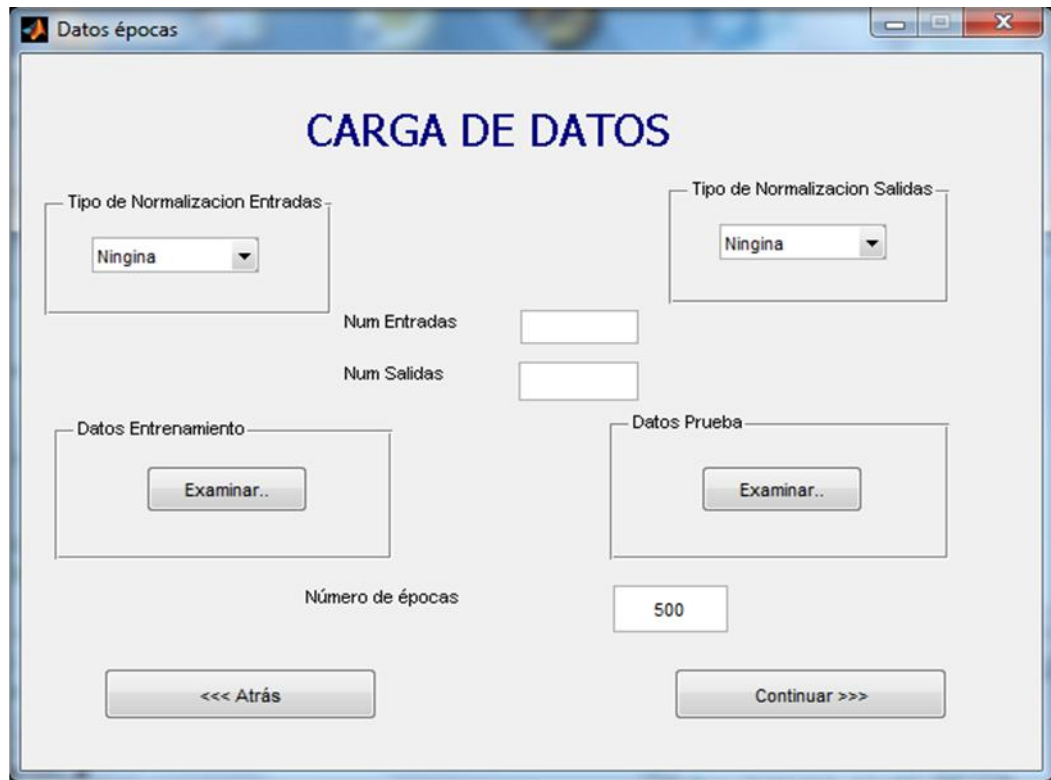
Por otro lado si se decide especificar las épocas solo se tendría que cargar el conjunto de datos de entrenamiento y prueba de la red. Adicionalmente se debe escoger el número de épocas durante la cual se va a realizar el entrenamiento de la red (**Fig. 2** y **Fig. 3**).

Fig. 2.. Carga de datos para detención temprana



Fuente. GALVIS, L; Y OCHOA, C. Desarrollo de una herramienta software utilizando redes neuronales artificiales para estimar propiedades del comportamiento mecánico de arenas limpias pertenecientes a una cuenca Colombiana. UIS. 2006

Fig. 3. Carga de datos especificando épocas



Fuente. GALVIS, L; Y OCHOA, C. Desarrollo de una herramienta software utilizando redes neuronales artificiales para estimar propiedades del comportamiento mecánico de arenas limpias pertenecientes a una cuenca Colombiana. UIS. 2006

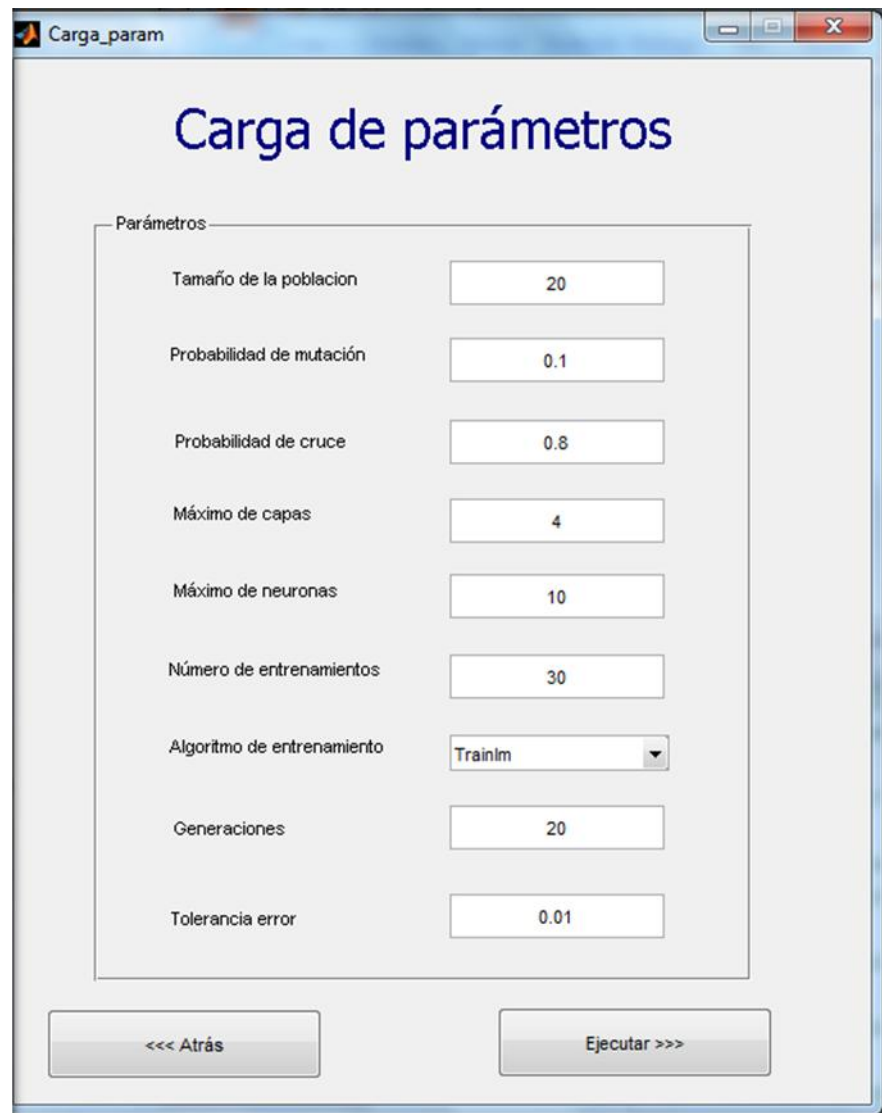
Para la carga de datos se definió un sencillo formato en el cual cada una de los conjuntos de entrenamiento se guarda en un archivo de texto plano con extensión .dat y mediante el programa se realiza la carga de cada uno de estos conjuntos.

CARGA DE PARAMETROS

El siguiente paso consiste en especificar el espacio de búsqueda del algoritmo genético y los demás datos que se van a usar en el problema, para esto se tiene (Ver **Fig. 4**):

- ◆ Tamaño de la población: Cantidad inicial de soluciones posibles consideradas, por defecto se utiliza el valor de 20 el cual es un valor estándar usado en algoritmos genéticos. El empleo de 20 individuos sirve para acelerar el desarrollo de los experimentos sin afectar a los resultados.
- ◆ Probabilidad de mutación: Determinación de la probabilidad que tiene los individuos de mutar un gen en cada ciclo del algoritmo genético, esto se hace para buscar diversidad. La probabilidad de mutación suele ser muy baja, por lo general entre el 0.5% y el 2%.
- ◆ Probabilidad de cruce: indica la probabilidad que tiene los individuos que sean seleccionados para jugar el papel de padres, y posteriormente ser combinados.
- ◆ Máximo de capas: indica el máximo número de capas que se va a utilizar en la búsqueda de las configuraciones.
- ◆ Máximo de neuronas por capas: selección del límite superior de neuronas que se van a probar para buscar la solución del problema.
- ◆ Numero de entrenamientos: selección del número de veces que se va a ser entrenada cada configuración, se recomienda usar una cantidad significativa de entrenamientos para garantizar que cada configuración logre explotar todo su potencial.
- ◆ Algoritmo de entrenamiento: selección del algoritmo con el cual se realiza el entrenamiento de cada una de las configuraciones.
- ◆ Generaciones: número de repeticiones durante las cuales se va a realizar la búsqueda de las configuraciones.
- ◆ Tolerancia al error: máximo valor de error permitido en la salida de la red para ser considerado una falla.

Fig. 4. Carga de parámetros



The screenshot shows a software window titled "Carga_param" with a main heading "Carga de parámetros". Below the heading is a section labeled "Parámetros" containing several input fields and a dropdown menu. At the bottom of the window are two buttons: "<<< Atrás" and "Ejecutar >>>".

Parámetro	Valor
Tamaño de la población	20
Probabilidad de mutación	0.1
Probabilidad de cruce	0.8
Máximo de capas	4
Máximo de neuronas	10
Número de entrenamientos	30
Algoritmo de entrenamiento	Trainlm
Generaciones	20
Tolerancia error	0.01

Fuente. GALVIS, L; Y OCHOA, C. Desarrollo de una herramienta software utilizando redes neuronales artificiales para estimar propiedades del comportamiento mecánico de arenas limpias pertenecientes a una cuenca Colombiana. UIS. 2006

Después de seleccionar cada uno de los parámetros se procede a realizar la ejecución del algoritmo donde se probaran las posibilidades para luego mostrar los resultados correspondientes.

VISUALIZADOR DE SOLUCIONES

Luego del proceso de búsqueda se muestran las soluciones encontradas, ordenadas de acuerdo al número de errores cometidos al evaluar cada configuración con los datos de prueba. En la parte izquierda se muestran las configuraciones finales encontradas en el algoritmo genético de acuerdo a un arreglo donde cada posición representa una capa oculta usada, mientras que el número representa las neuronas ocultas utilizadas en cada capa. Así pues la configuración (3 5 7), representaría una configuración con tres capas ocultas cada una con 3, 5,7 neuronas en cada capa respectivamente.

Al seleccionar cada una de estas configuraciones, se muestran algunos detalles sobre el comportamiento de las mismas. Las opciones se describirán a continuación:

1. Configuración de las capas ocultas: soluciones encontradas por el algoritmo.
2. Numero de errores: muestra el número de fallas cometidas al simular la red teniendo como referencia la tolerancia al error previamente seleccionada.
3. Peor error: indica el máximo error cometido al simular la configuración hallada.
4. Error promedio: indica la media de los errores cometidos en la salida de la red simulada.
5. Varianza de los errores: dispersión de los errores cometidos por la red neuronal para determinar la uniformidad de los mismos.
6. Funciones de activación: Muestra las funciones de activación usadas en cada una de las capas ocultas de la red neuronal. Así pues cada función

que aparece a la función de activación relativa a su posición en el arreglo mostrado.

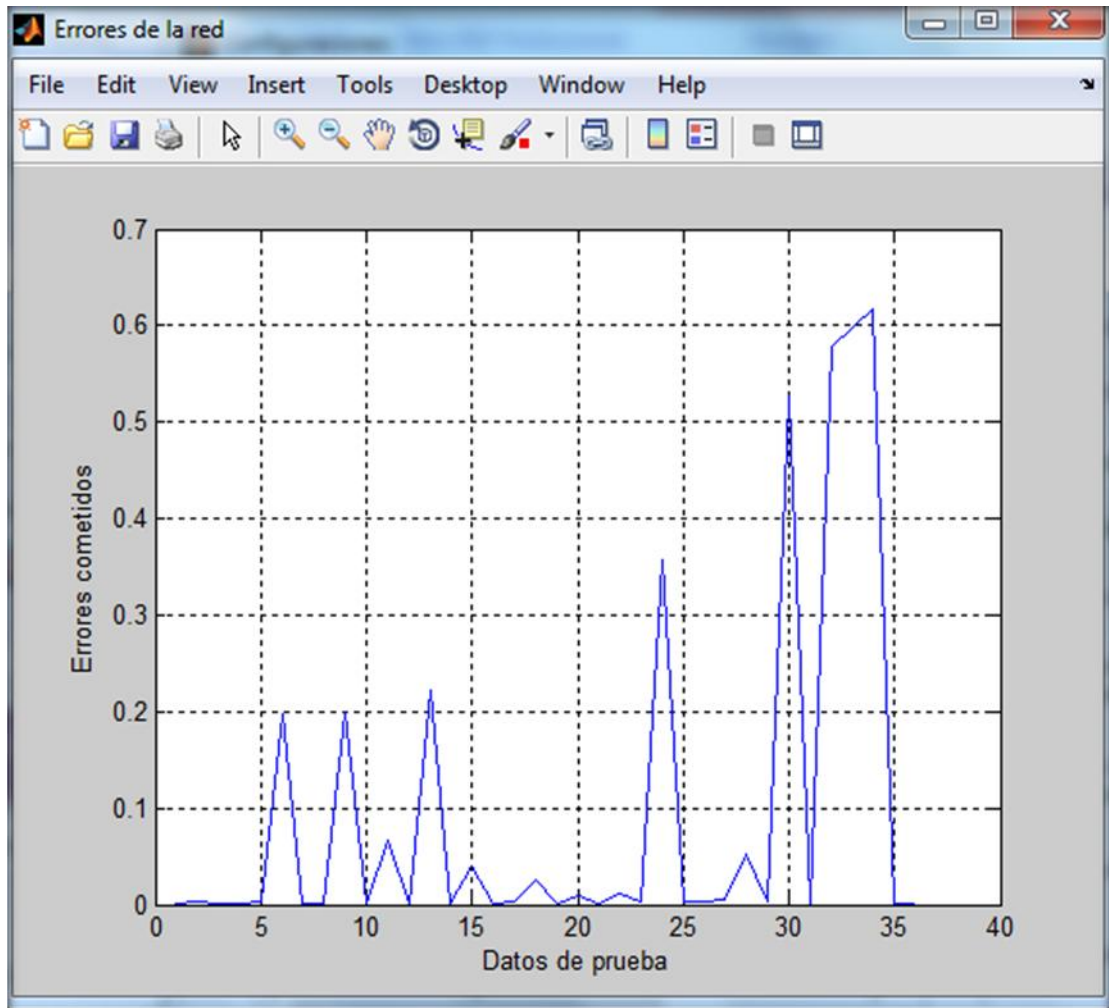
7. Función de activación: corresponde a la función de activación usada en la capa de salida en la configuración respectiva.
8. Grafica de errores: comportamiento de la salida de la red simulada con los datos de prueba (**Fig. 6**).
9. Guardar red: Una vez obtenidas las configuraciones que mejor se adapten al problema, se tiene la posibilidad de guardarlas para trabajar directamente sobre ellas. Esto es posible ya que cada una de las soluciones mostradas corresponde a la red neuronal entrenada que produce los valores que se indican. Estas redes se guardan en un archivo extensión .mat propio de Matlab, las cuales se puede posteriormente cargar al comando load.
10. Guardar como XML: recibe un objeto red neuronal y luego de procesarlo lo guarda en un archivo de extensión XML y que contiene en este mismo lenguaje la descripción de las partes de la neurored. Esta función se adaptó a la interfaz gráfica, para facilitar su manejo sobre el configurador, con esto, solo se debe escoger una ubicación y un nombre para que el programa guarde este archivo en el lugar que el usuario desee.
11. Al pulsar el botón Ver análisis, la herramienta presenta un análisis estadístico de la búsqueda realizada por el algoritmo genético: Error vs número de capas ocultas (**Fig. 7**), Redes probadas vs número de capas (**Fig. 8**), Errores vs número de neuronas por red (**Fig. 9**), Redes probadas vs número de neuronas por configuración (**Fig. 10**), Variación de los errores en las generaciones (**Fig. 11**).

Fig. 5. Ventana de configuraciones



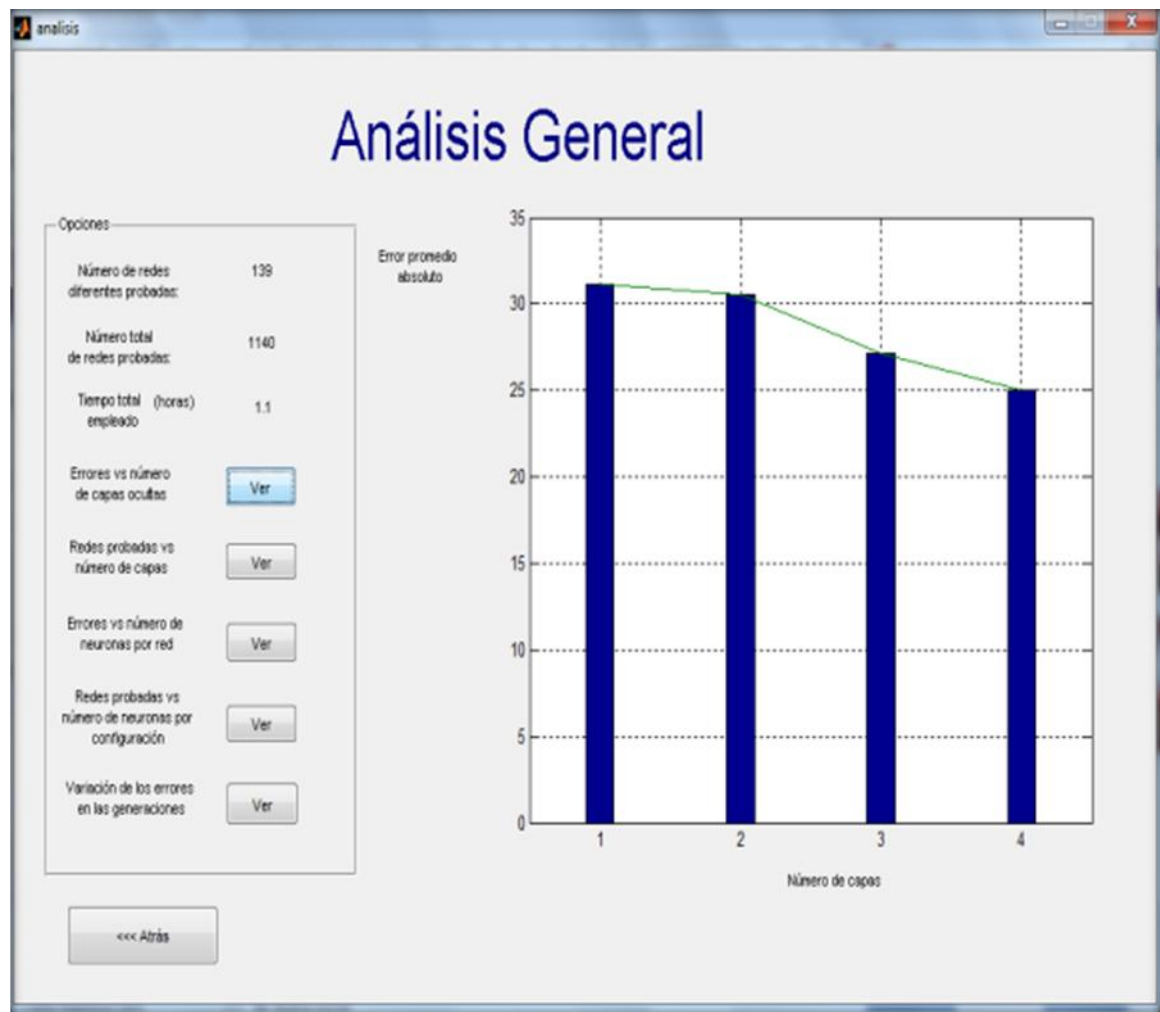
Fuente. GALVIS, L; Y OCHOA, C. Desarrollo de una herramienta software utilizando redes neuronales artificiales para estimar propiedades del comportamiento mecánico de arenas limpias pertenecientes a una cuenca Colombiana. UIS. 2006

Fig. 6. Errores de la red



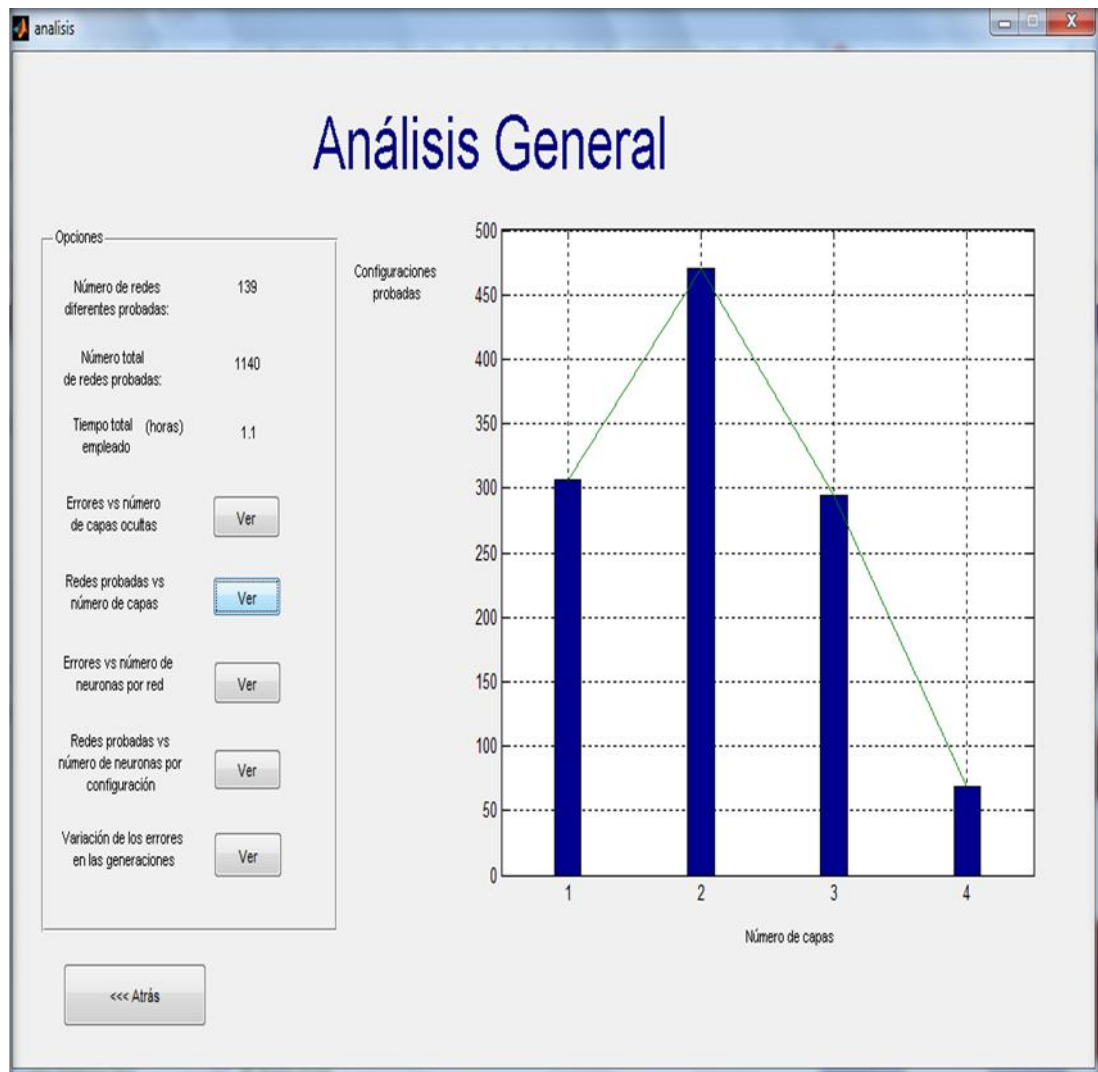
Fuente. GALVIS, L; Y OCHOA, C. Desarrollo de una herramienta software utilizando redes neuronales artificiales para estimar propiedades del comportamiento mecánico de arenas limpias pertenecientes a una cuenca Colombiana. UIS. 2006

Fig. 7. Errores vs numero de capas ocultas



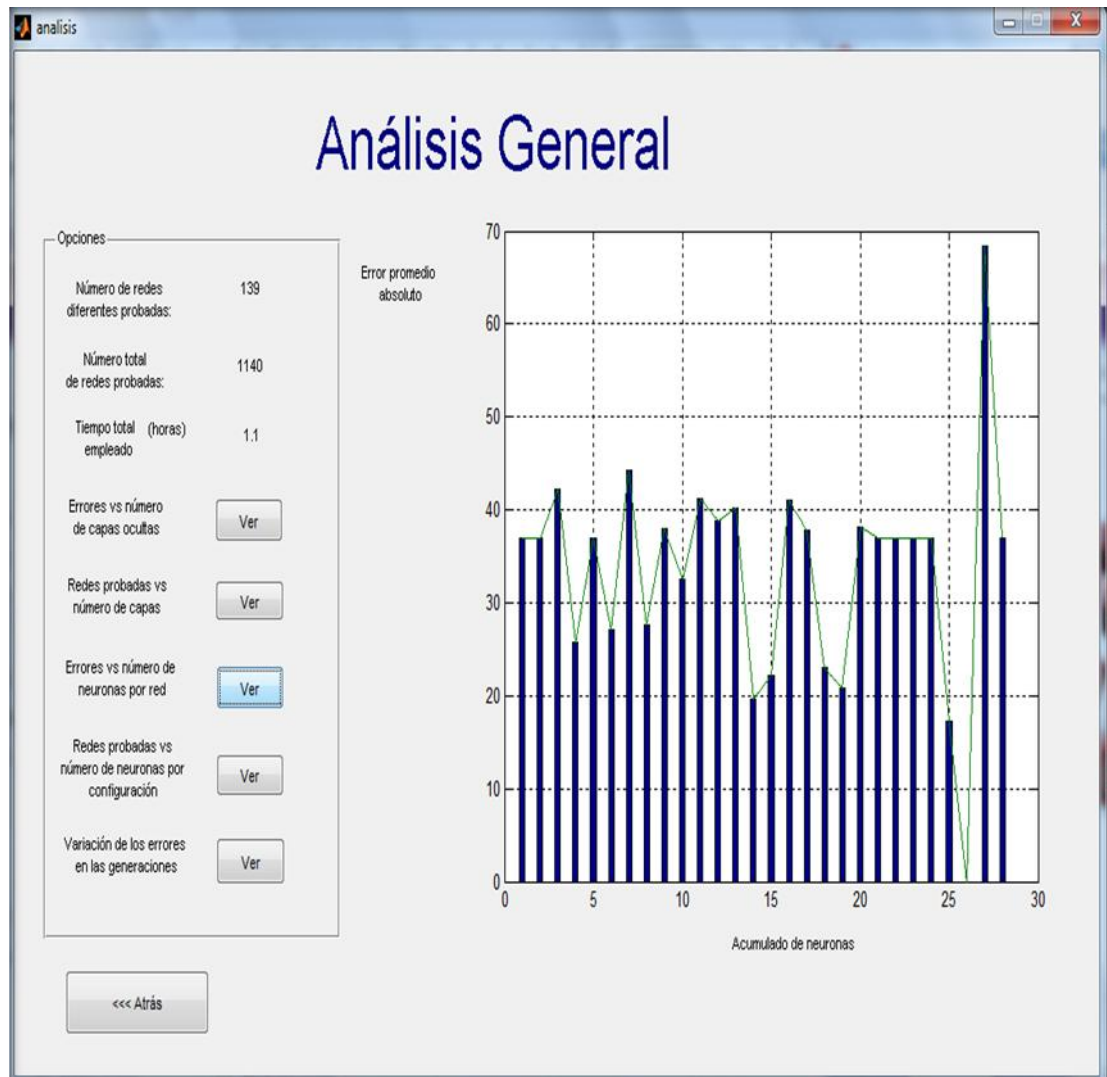
Fuente. GALVIS, L; Y OCHOA, C. Desarrollo de una herramienta software utilizando redes neuronales artificiales para estimar propiedades del comportamiento mecánico de arenas limpias pertenecientes a una cuenca Colombiana. UIS. 2006

Fig. 8. Redes probadas vs número de capas



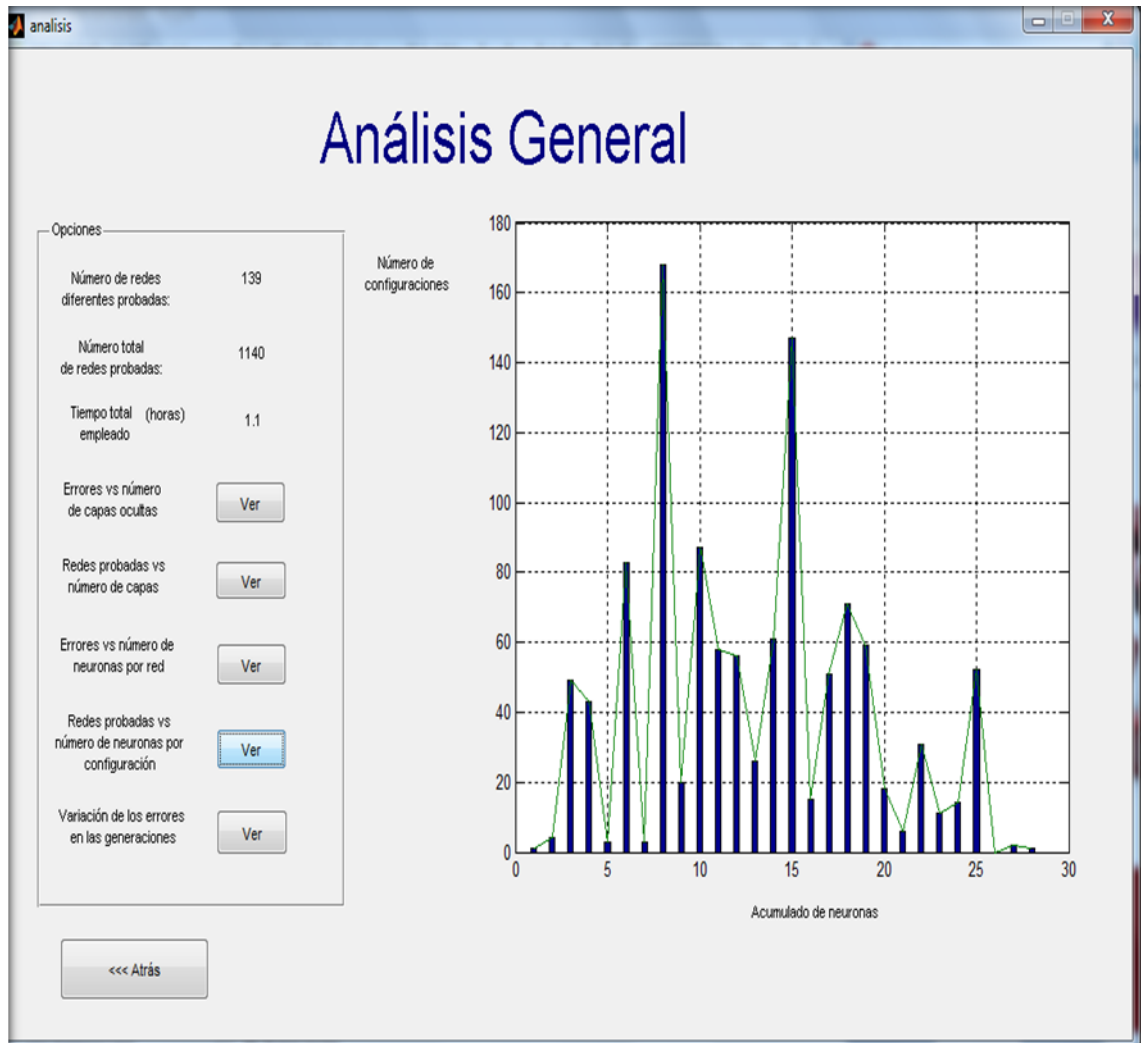
Fuente. GALVIS, L; Y OCHOA, C. Desarrollo de una herramienta software utilizando redes neuronales artificiales para estimar propiedades del comportamiento mecánico de arenas limpias pertenecientes a una cuenca Colombiana. UIS. 2006.

Fig. 9. Errores vs numero de neuronas por red



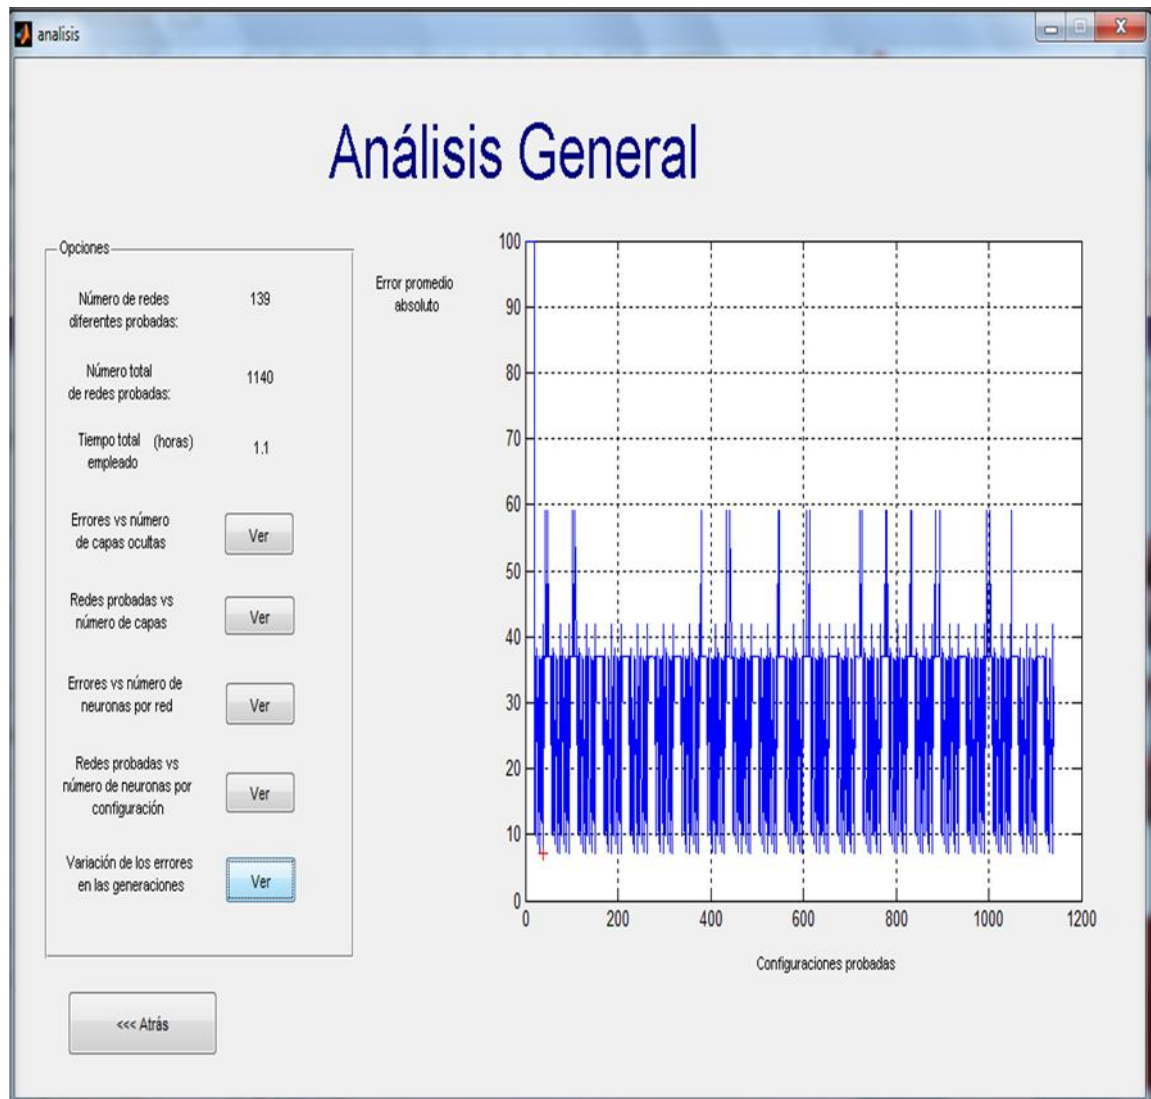
Fuente. GALVIS, L; Y OCHOA, C. Desarrollo de una herramienta software utilizando redes neuronales artificiales para estimar propiedades del comportamiento mecánico de arenas limpias pertenecientes a una cuenca Colombiana. UIS. 2006.

Fig. 10. Redes probadas vs número de neuronas por configuración.



Fuente. GALVIS, L; Y OCHOA, C. Desarrollo de una herramienta software utilizando redes neuronales artificiales para estimar propiedades del comportamiento mecánico de arenas limpias pertenecientes a una cuenca Colombiana. UIS. 2006.

Fig. 11. Variación de los errores en las generaciones



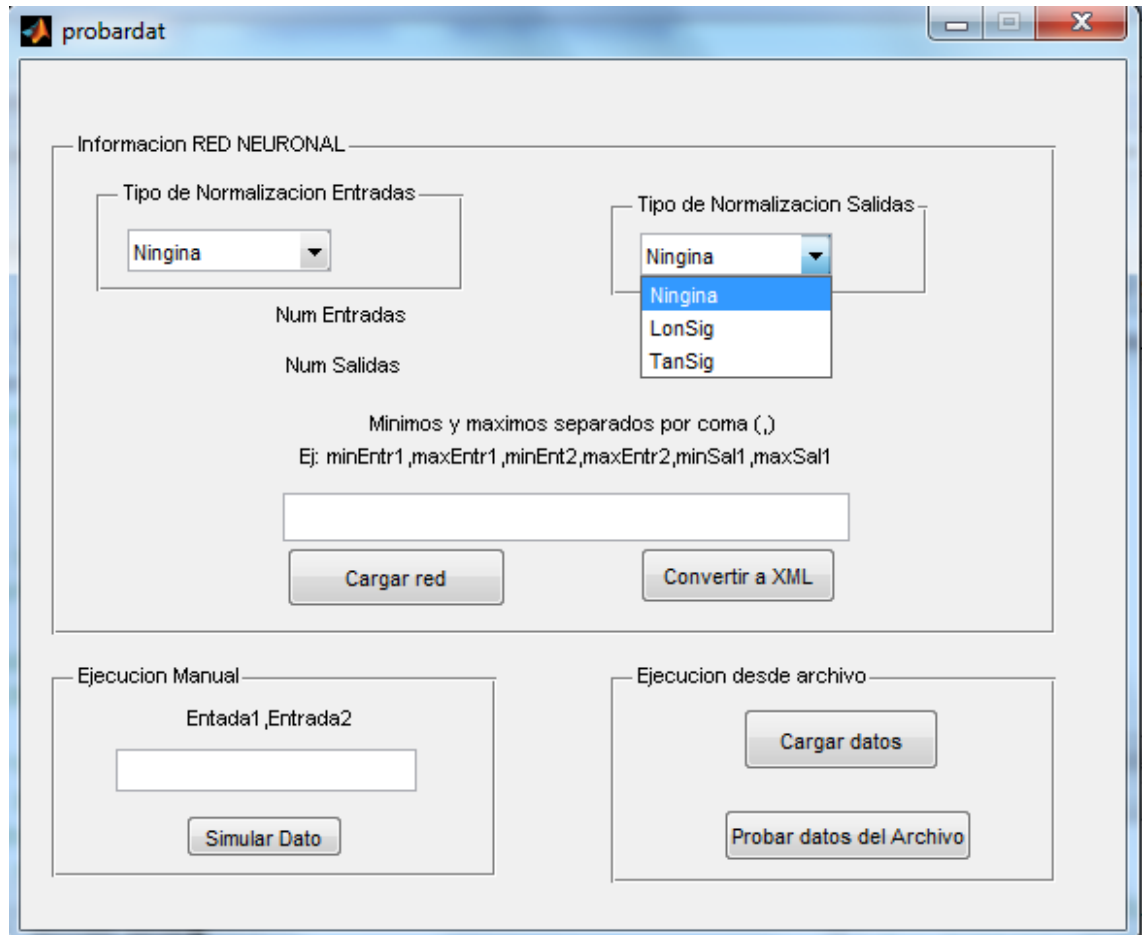
Fuente. GALVIS, L; Y OCHOA, C. Desarrollo de una herramienta software utilizando redes neuronales artificiales para estimar propiedades del comportamiento mecánico de arenas limpias pertenecientes a una cuenca Colombiana. UIS. 2006.

EXTENCIÓN PROBARDAT.M

Para la estimación final de los datos en los cuales se requiere la valoración de la propiedad a evaluar, se diseñó un nuevo vínculo que permite que el usuario calcule la propiedad de dos maneras. Individualmente con la selección de un

dato o adjuntando un archivo con extensión .dat, para cuando el set de datos es amplio (Fig. 12).

Fig. 12. Extensión probardat.m



Fuente. GALVIS, L; Y OCHOA, C. Desarrollo de una herramienta software utilizando redes neuronales artificiales para estimar propiedades del comportamiento mecánico de arenas limpias pertenecientes a una cuenca Colombiana. UIS. 2006.

Hay que seleccionar el tipo de normalización a utilizar (Ninguna, LonSing o TanSing), escribir los máximos y mínimos de los datos utilizados en el entrenamiento de la red y cargar los datos para la estimación. Los resultados son arrojados en un texto para su posterior evaluación.