

**DESARROLLO E IMPLEMENTACIÓN DE UN ALGORITMO DE
EVALUACIÓN DE CONDICIÓN INTEGRAL DE TRANSFORMADORES DE
POTENCIA Y REACTORES**

JAVIER ENRIQUE ACEVEDO ACEVEDO

**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICO - MECÁNICAS
ESCUELA DE INGENIERÍAS ELÉCTRICA, ELECTRÓNICA Y
TELECOMUNICACIONES
MAESTRÍA EN INGENIERÍA: ÁREA INGENIERÍA ELÉCTRICA
BUCARAMANGA**

2004

**DESARROLLO E IMPLEMENTACIÓN DE UN ALGORITMO DE
EVALUACIÓN DE CONDICIÓN INTEGRAL DE TRANSFORMADORES DE
POTENCIA Y REACTORES.**

JAVIER ENRIQUE ACEVEDO ACEVEDO

**Trabajo de investigación para optar al título de
Maestría en Ingeniería: Área de Ingeniería Eléctrica.**

Director

OSCAR GUALDRON GONZALEZ, Ph.D

**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICO - MECÁNICAS
ESCUELA DE INGENIERÍAS ELÉCTRICA, ELECTRÓNICA Y
TELECOMUNICACIONES
MAESTRÍA EN INGENIERÍA: ÁREA INGENIERÍA ELÉCTRICA
BUCARAMANGA**

2004

AGRADECIMIENTOS

El autor expresa sus agradecimientos al ingeniero Alberto Herreño por sus valiosos aportes a este trabajo. También al ing. Emil Monterrosa por su valiosa experiencia y colaboración fundamentales para la terminación de este trabajo.

DEDICATORIA

A mi esposa y compañera Adriana quien siempre me animó a culminar este trabajo. A mi hija Isabella quien sacrificó muchas horas de sus lecturas de cuentos. A mis padres Abelardo y Esther quienes han sido mis guías a lo largo de la vida.

JAVIER ENRIQUE

CONTENIDO

	Pág.
INTRODUCCIÓN	15
1. EL PROCESO DE ANÁLISIS DE CONDICIÓN DE EQUIPOS (ACE) AL INTERIOR DE INTERCONEXIÓN ELÉCTRICA S.A E.SP Y SUS IMPLICACIONES	16
1.1 EL PROCESO DE ANÁLISIS DE CONDICIÓN DE EQUIPOS (ACE) Y SU EVOLUCIÓN	16
1.2 INTEGRACIÓN DEL PROCESO ACE AL GERENCIAMIENTO DEL CICLO DE VIDA DE EQUIPOS	19
2. ESQUEMA DE EVALUACIÓN DE CONDICIÓN DE TRANSFORMADORES DE POTENCIA Y REACTORES	23
2.1 IDENTIFICACIÓN Y SELECCIÓN DE VARIABLES	23
2.2 OBTENCIÓN DE CRITERIOS DE EVALUACIÓN	37
2.3 OBTENCIÓN DE FACTORES PONDERADORES DE VARIABLES CALIFICADORAS Y DE REGLA EVALUADORA DE ASPECTOS	42
3. IMPLEMENTACIÓN DEL ESQUEMA DE EVALUACIÓN DE CONDICIÓN DE TRANSFORMADORES Y REACTORES USANDO TÉCNICAS CLÁSICAS Y DE INTELIGENCIA ARTIFICIAL	44
3.1 ANTECEDENTES DE LA APLICACIÓN DE INTELIGENCIA ARTIFICIAL AL PROCESO DE ANÁLISIS DE CONDICIÓN DE TRANSFORMADORES DE POTENCIA	44
3.2 REDES NEURONALES ARTIFICIALES	47
3.2.1 Características	47
3.2.2 Aplicaciones	49
3.2.3 Modelo Biológico	50

3.2.4 Elementos de una red neuronal artificial	51
3.2.5 Regla de Propagación	54
3.2.6 Estado de Activación	54
3.2.7 Función de Activación	54
3.2.8 Regla de Aprendizaje	57
3.2.9 Redes con aprendizaje supervisado	57
3.2.10 Redes con aprendizaje no supervisado	58
3.2.11 Desventajas de las Redes Neuronales	59
3.3 PERCEPTRÓN MULTICAPA	59
3.3.1 Funcionamiento	59
3.4 LÓGICA DIFUSA	61
3.4.1 Características	62
3.4.2 Aplicaciones	63
3.4.3 Elementos de un sistema de inferencia difuso	64
3.4.4 Proceso de inferencia difuso	66
3.4.5 Desventajas de la lógica difusa	69
3.5 SISTEMAS QUE COMBINAN LAS REDES NEURONALES Y LÓGICA DIFUSA	70
3.5.1 Modelos concurrentes	70
3.5.2 Modelos cooperativos	71
3.5.3 Modelos híbridos Neurodifusos	72
3.6 ANFIS	73
3.6.1 Características	73
3.6.2 Capas de neuronas en el ANFIS	75
3.6.3 Entrenamiento y funcionamiento	76
3.7 INTERPOLACIÓN DE DATOS	78
3.8 IMPLEMENTACIÓN DEL ESQUEMA DE EVALUACIÓN BAJO CADA UNA DE LAS TÉCNICAS PROPUESTAS	78
3.8.1 Preparación de información y elaboración de casos para entrenamiento, verificación y chequeo	79

3.8.2	Análisis de Componentes Principales (PCA).	82
3.8.3	Implementación del esquema de evaluación bajo la técnica de interpolación multidimensional	86
3.8.4	Implementación de la estrategia de evaluación usando sistemas híbridos neurodifusos	88
3.9	COMPARACIÓN DE RESULTADOS OBTENIDOS CON LAS DOS TÉCNICAS USADAS	95
4.	CONCLUSIONES	98
4.1	GENERALES	98
4.2	ESPECIFICAS	99
	BIBLIOGRAFIA	101

LISTA DE TABLAS

	Pág.
Tabla 1. Tecnologías de medición contempladas normalmente dentro de los esquemas de evaluación de condición de transformadores y reactores	24
Tabla 2 Resumen de modos de falla de probable ocurrencia en transformadores de potencia y reactores y las variables asociadas a su seguimiento.	26
Tabla 3. Resumen de las variables identificadas para inclusión en el esquema de evaluación	36
Tabla 4. Identificación de factores generadores de criterios particulares de evaluación o que dan lugar a errores en el diagnóstico para subpoblaciones de equipos	39
Tabla 5. Resumen comparativo de criterios y valores límite obtenidos para las diferentes variables evaluadoras.	41
Tabla 6. Grado de importancia identificado para cada una de las variables evaluadoras seleccionadas	43
Tabla 7. Resumen de esquemas de evaluación de condición de transformadores implementados con herramientas de inteligencia artificial.	46
Tabla 8. Algunas aplicaciones de las redes neuronales artificiales.	49
Tabla 9. Principales parámetros de la Red	60
Tabla 10. Algunas aplicaciones de la lógica difusa.	63
Tabla 11. Principales parámetros del ANFIS.	75
Tabla 12. Distribución de la población total de casos reales identificados.	80

Tabla 13. Valor de varianza porcentual para cada componente principal identificado.	84
Tabla 14. Resumen de resultados de error porcentual final usando técnicas de interpolación multidimensional.	87
Tabla 15. Resumen de variables consideradas en la evaluación de desempeño del esquema bajo sistemas híbridos neurodifusos.	89
Tabla 16. Resumen de resultados de error porcentual obtenido para los diferentes grupos de datos variando diferentes parámetros del sistema híbrido neurodifusos.	90

LISTA DE FIGURAS

	Pág.
Figura 1. Esquema jerárquico del proceso de evaluación de condición de equipos.	17
Figura 2. Forma general de un esquema de evaluación de condición de equipos.	28
Figura 3. Gases generados durante fallas dieléctricas en aceite aislante.	31
Figura 4. Zonas de clasificación de modos de fallas basadas en la norma IEC 599.	32
Figura 5. Estructura final obtenida para el esquema de evaluación de condición de transformadores y reactores.	35
Figura 6. Comportamiento de las principales variables estadísticas resumen para la rata de generación mensual de gases combustibles (TDGC rate).	38
Figura 7 Red Neuronal Artificial	48
Figura 8 Neurona biológica y sus principales partes	50
Figura 9. Sinapsis en la Neurona Biológica	51
Figura 10 Neurona artificial y sus partes	53
Figura 11 Funciones de activación lineal y sigmoideal respectivamente	56
Figura 12. Funciones de transferencia gaussiana (izq) y sigmoideal (der).	57
Figura 13 Conjuntos tradicionales y difusos, respectivamente	63
Figura 14. Elementos de una variable difusa.	65
Figura 15. Algunas formas de funciones de pertenencia	65
Figura 16. Sistema de inferencia difuso.	66
Figura 17. Proceso de fuzzificación de las entradas.	67

Figura 18. Método del centro de gravedad	69
Figura 19. Red neuronal, como preprocesador.	70
Figura 20. Red neuronal que deriva conjuntos difusos.	71
Figura 21. Red neuronal derivando reglas difusas.	72
Figura 22. Red neuronal aprendiendo factores de peso.	72
Figura 23. ANFIS con 2 entradas.	77
Figura 24. Superficie de control generada por el ANFIS	78
Figura 25. Gráfico de correlación entre el primer y segundo componente principal identificados.	85
Figura 26. Resultados de la aplicación del análisis de componentes principales PCA al archivo de datos seleccionados.	85
Figura 27. Error de entrenamiento para sistema híbrido neurodifusos generado por subsectorización.	91
Figura 28. Error de entrenamiento para sistema híbrido neurodifusos generado por partición de red.	92
Figura 29. Comparación entre salida de resultados del sistema híbrido y los datos de entrenamiento para el grupo de chequeo en uno de los casos.	92
Figura 30. Comportamiento del error promedio obtenido para los diferentes grupos de datos variando el número de entradas.	93
Figura 31. Comportamiento del error promedio obtenido para sistema de generación por “partición de red” variando el número de funciones de membrecía.	93
Figura 32. Comportamiento del error promedio del esquema de evaluación para las dos técnicas consideradas.	95
Figura 33. Ejemplo de comportamiento inestable en el proceso de entrenamiento de una red híbrida neurodifusos.	96

RESUMEN

La evaluación de condición integral de transformadores es una tarea compleja dado la gran cantidad de variables consideradas y el conocimiento y experiencia involucrados en su ejecución. La ejecución manual de este proceso sobrepasa la mayoría de las veces la capacidad logística y los recursos disponibles en las empresas de transmisión y distribución de energía eléctrica. Por lo anterior, en Interconexión Eléctrica S.A E.S.P se consideró importante y necesario el desarrollo de un algoritmo que a través de su ejecución automática permitiera reducir el tiempo requerido para evaluar la condición integral de la población de transformadores y reactores que componen su red de transmisión.

El desarrollo del algoritmo contempló varias etapas como la selección de variables calificadoras, construcción de criterios de evaluación, evaluación de desempeño, refinación, ajuste e implementación final del algoritmo para lo cual se usaron técnicas de interpolación multidimensional y sistemas híbridos neurodifusos. Se tomaron como base alrededor de 800 casos reales previamente evaluados y con diferentes niveles de criticidad obtenidos de la base de datos de actividades de mantenimiento realizadas en ISA en los últimos siete años, seleccionando grupos de casos para entrenamiento y verificación de desempeño.

Los resultados finales del error de calificación a la salida del algoritmo desarrollado fueron óptimos para las dos técnicas usadas, estando por debajo del 6% en la mayoría de los casos y siendo ligeramente mejor el desempeño para la técnica de sistemas híbridos neurodifusos. Con la implementación del algoritmo se logró un significativo ahorro de tiempo y recursos en la ejecución del proceso de evaluación de condición de transformadores en ISA mejorando adicionalmente la transferencia de conocimiento y experiencia alrededor de este proceso en la organización.

SUMMARY

Condition assessment in power transformers is a very complex task due to the number of variables and aspects to be considered and the knowledge and experience involved in its execution. Non automated execution of this task generally overpasses the capability of the human resources available in the electrical utilities. Due to the before mentioned, in Interconexión Eléctrica S.A E.S.P, the development of an algorithm to execute the power transformer condition assessment automatically as a way to reduce the time spent in its execution was considered too important and necessary.

The development of the algorithm was done in several stages such as variable selection, evaluation criteria construction, performance evaluation, adjust and final implementation. In this last stage, two techniques were considered, multidimensional interpolation and hybrid neurofuzzy systems. A set of 800 previously evaluated cases of power transformers were obtained from the historical records of the maintenance activities done in the latest seven years and saved in the ISA's maintenance database. The cases were classified in training and checking groups to evaluate the performance of algorithm.

Final evaluation of the error given by the algorithm using the two techniques showed optimum values (typically lesser than 6%) although the performance of hybrid neurofuzzy systems was better than multidimensional interpolation. Considerable savings in time and human resource involved in the execution of power transformer condition assessment process was obtained with the implementation and using of the algorithm. The knowledge and experience transferring process in the organization was improved too.

INTRODUCCIÓN

Los transformadores de potencia y reactores de línea son los equipos más costosos dentro de un sistema de transmisión y su falla ocasiona quizá el mayor impacto tanto desde el punto de vista económico como de disponibilidad. La evaluación de su condición integral es una tarea compleja dada la gran cantidad de variables que se deben considerar. Los criterios de evaluación de algunas de estas variables, establecidos en normas y guías internacionales algunas veces no se ajustan bien al comportamiento histórico mostrado por las mismas y no tienen en cuenta aspectos ambientales y operativos particulares de cada equipo. Evaluar y determinar de forma manual la condición integral de todos los equipos de transformación de una compañía de transmisión y generar posteriormente las acciones correctivas que permitan recuperar esta condición, sobrepasa la mayoría de las veces la capacidad logística disponible en cuanto a recurso humano calificado y tiempo. Por lo anterior en Interconexión Eléctrica S.A E.S.P, ISA, se consideró importante y necesario el desarrollo de una herramienta que permitiera reducir el tiempo de análisis necesario para la evaluación de condición de transformadores y reactores a través del uso de criterios bastante ajustados al comportamiento histórico de cada variable. En el presente trabajo se describe el procedimiento usado para la obtención de dichos criterios así como para la implementación del algoritmo de evaluación. Asimismo se hace uso de una técnica neurodifusa basada en inteligencia artificial así como también de una técnica clásica de interpolación usada en la solución de este tipo de problemas para lograr el desarrollo inicial de un software que permita, en forma automática, realizar la evaluación de condición integral de la población de transformadores y reactores de ISA.

1. EL PROCESO DE ANÁLISIS DE CONDICIÓN DE EQUIPOS (ACE) AL INTERIOR DE INTERCONEXIÓN ELÉCTRICA S.A E.SP Y SUS IMPLICACIONES

1.1 EL PROCESO DE ANÁLISIS DE CONDICIÓN DE EQUIPOS (ACE) Y SU EVOLUCIÓN

El análisis de condición es el proceso por el cual a través de una evaluación cualitativa de una serie de variables generalmente obtenidas de pruebas y análisis realizados, se determina el estado, funcionalidad y la existencia de modos de falla que afectan el desempeño de los mismos. Este proceso es una tarea compleja debido en parte a la gran cantidad de variables objeto de evaluación y aspectos a considerar. Su complejidad aumenta en la medida que se incorporan más aspectos en el análisis por lo que para su realización se establecen diferentes niveles dependiendo del grado de conocimiento y experiencia requeridos para su ejecución así como el alcance y extensión requeridos de los resultados. La Figura No 1 describe el alcance de los diferentes niveles del esquema de análisis de condición de equipos actualmente usado en ISA el cual es similar al usado por muchas otras compañías en el mundo [1], [2], [3] y [4].

El primer nivel de evaluación normalmente se realiza en campo o en el laboratorio durante la ejecución de pruebas y análisis y permite identificar la desviación de alguno o algunos de los valores obtenidos para las variables evaluadas respecto a unos valores base previamente definidos. Tan pronto se identifica alguna desviación, se genera la necesidad de aplicación de un nivel de análisis mas detallado. Este segundo nivel contempla la evaluación

de tendencias de crecimiento de algunas de las variables, su ponderación y la obtención de una calificación para cada uno de los dos aspectos claves evaluados para el desempeño de un equipo como son la existencia de modos de falla en evolución y la existencia de señales de envejecimiento acelerado de los aislamientos. Los resultados obtenidos para los dos factores claves mencionados anteriormente determinan la calificación de la condición integral del equipo, la cual se evalúa entre 0 y 5 determinándose los siguientes niveles a saber:

- Condición 0: Equipo fallado.
- Condición 1: Equipo en estado crítico.
- Condición 2: Equipo bajo cuestionamiento.
- Condición 3: Equipo en estado regular.
- Condición 4: Equipo en buen estado.
- Condición 5: Equipo en condición excelente.

Figura 1. Esquema jerárquico del proceso de evaluación de condición de equipos.



Esta calificación es usada posteriormente para determinar la prioridad de ejecución de acciones de mantenimiento encaminadas a recuperar la condición óptima del equipo afectado. A los equipos calificados con condición entre 4 y 5 no se les realiza acciones diferentes a las estipuladas en el Plan de Mantenimiento establecido. Para los equipos evaluados entre 2 y 4 se realizan acciones de seguimiento que van desde modificación de la periodicidad de ejecución de análisis y pruebas, la instalación de sistemas de monitoreo en línea de variables claves hasta el establecimiento de consignas operativas con límites de carga o tensión por debajo de los nominales o la inspección interna del equipo.

El tercer nivel de análisis evalúa información sobre la historia de desempeño de los equipos teniendo en cuenta aspectos operativos (curva de carga diaria típica, niveles máximos de sobrecarga y sobre tensión experimentados), climatológicos [5] (nivel de descargas atmosféricas en la zona, oscilaciones máximas de temperatura ambiente, polución ambiental, humedad relativa en la zona), mecánicos (impacto acumulado de altas corrientes circulantes a través de devanados producto de fallas) y tecnológicos [6], [7] (factores de seguridad usados en diseño y construcción, tipo de núcleo, sistema de fijación del conjunto de devanados, materiales aislantes usados). Los resultados obtenidos de esta evaluación pueden confirmar la calificación obtenida en el segundo nivel o por el contrario reducir el nivel de alarma generado al confirmarse la no-afectación de la condición del equipo en el grado inicialmente asumido.

La aplicación de este esquema jerárquico de análisis permite la optimización de los recursos utilizados en el proceso al enfocarse fuertemente en el análisis de aquellos equipos cuya condición lo amerita. Adicionalmente permite la generación de señales objetivas para planes de reposición de unidades a mediano y largo plazo.

Con la evolución de las estrategias de mantenimiento, también han evolucionado algunos conceptos clásicos sobre la efectividad y predictibilidad de algunas tareas de mantenimiento. Es así como a través de la aplicación de la estrategia de Mantenimiento Centrado en Confiabilidad (RCM) se han redefinido algunas tareas de mantenimiento clasificadas dentro del mantenimiento predictivo. Tareas que antes se asumían como predictivas tales como medición de resistencia ohmica y medición de corriente de excitación de devanados para el caso de transformadores han quedado establecidas como “tareas de búsqueda de fallos” ya que la información que suministran permite determinar si ha existido afectación de un componente, en este caso el devanado, pero no permite seguir la evolución del modo de falla ni dar tempranas señales de su existencia. Esta evolución de conceptos ha influenciado la estructura de los actuales esquemas de evaluación influyendo directamente sobre los factores ponderadores o factores de peso de cada variable seleccionada que indirectamente determinan su importancia.

1.2 INTEGRACIÓN DEL PROCESO ACE AL GERENCIAMIENTO DEL CICLO DE VIDA DE EQUIPOS

El proceso de gerenciamiento de activos es el proceso por el cual se maneja en forma integral el ciclo de vida de los equipos para hacer uso de ellos en forma costo-efectiva. La importancia del proceso radica en las implicaciones de sus decisiones sobre el ciclo de vida del equipo como son la realización de mantenimientos mayores (**overhauling**) y su reemplazo total o parcial cuando sus costos de mantenimiento son altos y empiezan a afectar la rentabilidad del activo.

La toma estratégica de estas decisiones está basada en un enfoque bidimensional que tiene en cuenta la probabilidad de ocurrencia de una falla

en el equipo y su severidad o consecuencias. Cada transformador llega inevitablemente al final de su vida y las consecuencias directas o indirectas de esta falla (energía no servida, destrucción de otros equipos alrededor, afectación de seres humanos, impacto ambiental por derrame del aceite, costos de reparación, costos de disposición final de unidad fallada, afectación de imagen corporativa, etc.) valoradas económicamente, conforman la severidad la cual puede ser estimada previamente. El riesgo está asociado a no conocer cuando esta falla ocurrirá lo que se conoce como frecuencia de falla. La valoración final del riesgo esta dada por la composición de los dos factores mencionados. No siempre el escenario que involucra el mayor riesgo es el escenario con la mayor frecuencia de falla ni el de mayor severidad asociada.

Algunas compañías han implementado este esquema de manejo del riesgo de falla de sus equipos a través del cálculo de una sola variable que conjuga los dos aspectos anteriormente descritos y denominados factor de consecuencia y factor de probabilidad. Con base en esta variable, se clasifican los diferentes equipos que componen la población objeto de estudio para determinar la extensión en la cual cada uno debe ser mantenido, inspeccionado y operado en el futuro.

El factor de consecuencia comprende las pérdidas económicas directas ocasionadas por la falla del equipo y el impacto estratégico del equipo donde se tienen en cuenta aspectos intangibles como la confiabilidad del sistema, consumidores críticos e importantes, imagen de la empresa, afectación del funcionamiento de instalaciones de seguridad social pública, daños ambientales, daños a equipos adyacentes, costos de litigios judiciales, multas y otros costos potenciales asociados al sitio específico de instalación.

El factor de probabilidad reúne una serie de aspectos identificados como críticos y asociados al desempeño del equipo los cuales han sido identificados por diferentes grupos de expertos. Cada aspecto es ponderado por un factor de peso de acuerdo a su importancia dentro del esquema total de evaluación. Es en este punto donde el análisis de condición de equipos (ACE) hace su aporte al esquema de gerenciamiento del ciclo de vida. Algunos de los aspectos considerados son:

- Aspectos tecnológicos de diseño y construcción: La ausencia de avanzados programas de computación en los años 70's hizo que algunos transformadores fabricados en esa época y anteriores involucraran mayores factores de seguridad en su diseño y construcción lo que les daba una mayor capacidad de carga o un funcionamiento a plena carga con menores temperaturas de operación. En contraste, otros aspectos como el flujo de dispersión (flujo que no sigue el camino principal a través del núcleo magnético) no fueron adecuadamente previstos lo que da lugar a la mayor probabilidad de ocurrencia de puntos calientes localizados en diferentes puntos del núcleo o del tanque.
- Tiempo de servicio: El tiempo de servicio es un factor directamente relacionado con el deterioro de los elementos aislantes del transformador siendo particularmente más importante en el proceso de deterioro del papel por ser este un fenómeno irreversible en contraste con el deterioro del aceite el cual puede ser revertido a través de procesos de regeneramiento del aceite en sitio y con el equipo energizado.
- Historia operativa: La valoración de los esfuerzos a que ha sido sometido el equipo es un factor importante a considerar en la evaluación de su condición actual y su tendencia futura. Una variable importante a tener en cuenta es la temperatura a que han sido sometidos los devanados ya que

es un factor que incide directamente sobre el fenómeno de degradación del papel acelerándolo. Asimismo, frecuentes energizaciones y altas corrientes circulantes en devanados producto de fallas cercanas a bornes del transformador pueden inducir la deformación mecánica de los devanados disminuyendo gradualmente su resistencia mecánica ante la ocurrencia de fallas.

- Historial de actividades de mantenimiento: La recopilación del registro histórico de actividades de mantenimiento es una fuente importante de información para evaluar la actual condición del equipo y realizar su proyección futura.
- Historial de resultados de pruebas de campo y análisis de laboratorio: A través de esta información se puede determinar el estado de evolución de los fenómenos de degradación de los materiales aislantes y generar la necesidad de efectuar acciones de mantenimiento de tipo correctivo para revertir los mismos o minimizar sus consecuencias en caso que sean irreversibles.

2. ESQUEMA DE EVALUACIÓN DE CONDICIÓN DE TRANSFORMADORES DE POTENCIA Y REACTORES

2.1 IDENTIFICACIÓN Y SELECCIÓN DE VARIABLES

El esquema de evaluación de condición de transformadores y reactores es quizá uno de los más complejos dado la gran cantidad de variables que se requiere evaluar. Adicionalmente, el gran grupo de modos de falla de probable ocurrencia asociados algunas veces a aspectos específicamente relacionados con la tecnología de diseño y construcción utilizada y los procesos de deterioro influenciados por múltiples factores, hacen de él, un proceso que requiere de mucha experiencia y conocimiento para llegar a conclusiones objetivas y efectivas. Algunos expertos en el tema [8], [9] han propuesto diferentes esquemas de evaluación los cuales tienen muchos aspectos en común diferenciándose algunas veces en los criterios de evaluación usados, algunos más conservadores que otros, otras veces en la tecnología o método de medición o análisis utilizados, y en la inclusión de mayor o menor número de modos de falla de probable identificación. Las tablas 1 y 2 muestra un resumen comparativo de las metodologías normalmente consideradas por las diferentes compañías para la evaluación de condición de transformadores donde se indica a su vez, si son de tipo predictivo (prueba de rutina) o de búsqueda de fallos lo cual se determina aplicando los principios básicos del MCC (Mantenimiento Centrado en Confiabilidad) y evaluando y analizando información del comportamiento de las variables durante fallas y eventos ocurridos en diferentes compañías.

Tabla 1. Tecnologías de medición contempladas normalmente dentro de los esquemas de evaluación de condición de transformadores y reactores

Prueba	Fallas detectadas	Capacidad de localización de la falla	Costo y Conveniencia	Uso
Análisis de Gases Disueltos (DGA)	Descarga Sobrecalentamiento	Ninguna	Fácil y económico. Puede hacerse con el equipo en servicio.	Prueba de Rutina
Análisis de compuestos furánicos	Envejecimiento de papel y puntos calientes	Ninguna	Fácil y económico. Puede hacerse con el equipo en servicio	Prueba de Rutina
Radio Interferencia	Descarga	Ninguna o Parcial (depende de la localización de la falla)	Fácil y económico. Puede hacerse con el equipo en servicio	Prueba de Rutina
Factor de Potencia	Condición del aislamiento papel-aceite.	Parcial	Costosa. Requiere desenergización y desconexión del equipo.	Búsqueda de fallos
Análisis de Respuesta en Frecuencia (FRA)	Condición mecánica de los devanados.	Parcial	Costosa. Requiere desenergización y desconexión del equipo.	Búsqueda de fallos
Espectro de Polarización	Envejecimiento de papel por humedad.	Ninguna	Costosa. Requiere desenergización del equipo.	Búsqueda de fallos o prueba de rutina en un mantenimiento mayor.
Resistencia ohmica de devanados	Condición eléctrica del devanado.	Parcial	Costosa. Requiere desenergización y desconexión del equipo.	Búsqueda de fallos
Emisión Acústica	Descarga	Buena (sí la descarga no está localizada dentro del devanado)	Costo Moderado. Puede hacerse con el equipo en servicio	Búsqueda de fallos
Inspección termográfica	Bloqueos del sistema de enfriamiento, Corrientes circulantes en el tanque por flujo de dispersión.	Buena	Costo Moderado. Puede hacerse con el equipo en servicio	Prueba de Rutina

La determinación de las variables a incluir en un esquema de evaluación de condición de equipos depende en gran parte del desarrollo tecnológico asociado a la estrategia de mantenimiento de cada compañía en particular. Es difícil incluir variables de evaluación obtenidas a partir de metodologías de diagnóstico que no se encuentren implementadas dentro del esquema de mantenimiento de la compañía o que no posean una adecuada cantidad de información histórica para evaluar tendencias particulares de crecimiento de dichas variables.

Dentro del proceso de selección e integración de variables a incluir en el esquema de evaluación de condición se debe tener en cuenta la capacidad y efectividad de identificación de modos de falla asociada a cada una de ellas así como también si los modos de falla que identifican son de alto impacto para la condición normal del equipo (irreversibles) o por el contrario pueden ser controlables (reversibles). De igual forma se debe identificar la forma en que evoluciona cada uno de los modos de falla, si su evolución implica rápido cambio de condiciones de componentes y no permite la oportuna implementación de acciones correctivas o si por el contrario, esta es relativamente lenta comparada con el ciclo total de vida esperada del equipo el cual es de alrededor de 40 años para transformadores de potencia [10]. En las tablas 3 a 6, se han resumido los principales modos de falla de más probable incidencia en transformadores con el correspondiente componente o subsistema que se ve afectado y con las variables relacionadas con su evolución.

De esta tabla se puede observar que el análisis de gases disueltos es una metodología que permite identificar la existencia y evolución de una gran cantidad de modos de falla lo que motiva su obligatoria inclusión en cualquier esquema de evaluación de condición.

Tabla 2 Resumen de modos de falla de probable ocurrencia en transformadores de potencia y reactores y las variables asociadas a su seguimiento.

Componente o subsistema	Modo de falla	Aspectos a monitorear	Variables de monitoreo	Reversible o Irreversible
Aislamientos (aislamiento mayor, aislamiento menor, terminales, pantalla electrostática, aceite aislante)	Reducción de propiedades dieléctricas	Humedad en aislamiento	Humedad en aceite y aislamiento, Medición de factor de potencia	Reversible
		Contaminación del aceite aislante por partículas	Conteo de partículas, rigidez dieléctrica	Reversible.
		Envejecimiento de celulosa	Contenido de furanos, Análisis gases disueltos	Irreversible
		Envejecimiento del aceite	Tensión Interfacial y Número de Neutralización	Reversible
Circuito electromagnético (núcleo, devanados, estructura de fijación, blindaje magnético, circuito de aterrizamiento)	Afectación del circuito magnético	Pérdida de aislamiento entre láminas del núcleo.	Corriente de excitación, Análisis gases disueltos	Irreversible
Circuito electromagnético (núcleo, devanados, estructura de fijación, blindaje magnético, circuito de aterrizamiento)	Afectación del circuito magnético	Sobrecalentamiento localizado por flujos de dispersión.	Análisis gases disueltos	Irreversible
	Afectación del circuito eléctrico	Deformación mecánica de devanados	Respuesta en frecuencia, Impedancia de cortocircuito	Irreversible
		Cortocircuito en devanados	Resistencia ohmica devanados, Análisis gases disueltos	Irreversible
		Contactos defectuosos en terminales	Resistencia ohmica devanados, Análisis gases disueltos	Reversible
		Deformación de estructura de soporte de terminales de salida	Respuesta en frecuencia, Impedancia de cortocircuito	Reversible
Cambiador de tomas bajo carga	Afectación de calidad del contacto	Desalineamientos, desgaste, sobrecalentamientos, deficiente presión de contacto	Inspección visual, Análisis gases disueltos, medición de torque.	Reversible
	Afectación de propiedades dieléctricas	Contaminación del aceite y barreras aislantes.	Medición de contenido de partículas, Tensión Interfacial y Número de Neutralización	Reversible
	Afectación del ciclo normal de operación	Integridad mecánica de componentes, velocidad de operación, Correcta sincronización de la operación.	Medición de tiempos de operación, velocidad y desplazamiento del mando. Análisis de gases disueltos.	Reversible
Bujes	Afectación de propiedades dieléctricas	Humedad en aislamiento	Contenido de humedad en aceite, Medición de factor de potencia.	Irreversible
		Contaminación del aceite aislante	Medición de factor de potencia, Análisis fisicoquímicos de aceite.	Irreversible

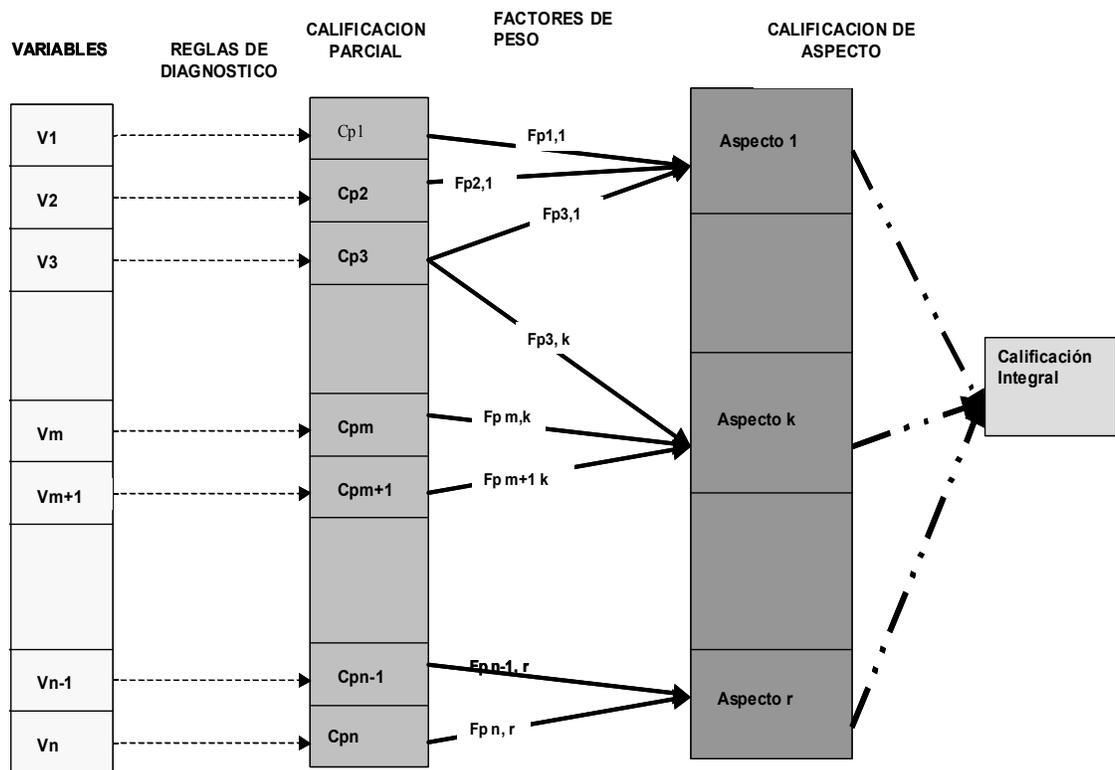
Para el caso particular de ISA y tomando como base el desarrollo tecnológico actual de su estrategia de mantenimiento así como el hecho que posee un gran historial de resultados de pruebas de campo, análisis de laboratorio y actividades de mantenimiento que abarca mas de 10 años, se decidió desarrollar un esquema de evaluación de condición sustentado en criterios objetivos obtenidos a partir de dicho historial. Por otro lado y teniendo en cuenta que el historial de fallas de transformadores y reactores ha sido muy bajo y por consiguiente se posee muy poca información de la evolución de las diferentes variables en estos casos, se determinó que el esquema de evaluación estuviera enfocado a la identificación objetiva de los casos de probable anomalía, más que identificar el tipo de modo de falla en evolución. Lo anterior debido a que para lograr esta última identificación se requiere una gran cantidad de datos asociados a condiciones de falla y avería los cuales permiten identificar y extraer patrones particulares de comportamiento de cada una de las variables calificadoras. Una vez identificado el alcance de la estrategia de evaluación a desarrollar y tomando como base experiencias anteriores dentro de la misma ISA así como de otras importantes compañías del sector eléctrico en el ámbito mundial, se identificaron cuatro posibles estados asociados al desempeño de un equipo a saber:

- Estado de funcionamiento normal, con presencia de procesos de deterioro, envejecimiento y desgaste que evolucionan normalmente de acuerdo con lo esperado.
- Estado de funcionamiento anormal con desarrollo de modos de falla que implican cambios en el patrón normal de generación de gases y / o afectación de propiedades dieléctricas de aislamiento. Por lo general implica existencia de modos de falla de rápida evolución que requieren la aplicación de acciones correctivas rápidas.

- Estado de funcionamiento anormal con evolución acelerada de fenómenos de deterioro, envejecimiento y degradación de componentes. Generalmente se asocia a modos de falla de evolución lenta los cuales pueden ser manejados a través de acciones correctivas cuya ejecución puede ser programada en el tiempo.
- Una combinación de los dos anteriores estados.

De acuerdo con lo anterior se desarrolló un esquema de evaluación de condición integral que permite la identificación y discriminación de los estados descritos anteriormente. La forma general del esquema de evaluación se muestra en la figura 2.

Figura 2. Forma general de un esquema de evaluación de condición de equipos.



Teniendo en cuenta los estados posibles en que un equipo se puede encontrar cumpliendo sus funciones, se determinaron dos aspectos generales a evaluar sobre su desempeño con el fin de determinar la condición asociada al mismo:

- Existencia de modos de falla de evolución rápida con alto riesgo de afectación para el equipo y que implican la rápida ejecución de acciones correctivas.
- Existencia de fenómenos de degradación y deterioro de componentes con lenta evolución y cuya solución permite acciones correctivas programadas a corto o mediano plazo.

Estos aspectos generales están relacionados a su vez con diferentes variables que evalúan modos de falla particulares enmarcados dentro de cada uno de estos aspectos. Es así como la existencia de modos de falla de rápida evolución aparece relacionado con variables que identifican generación anormal de gases, contaminación de aislamientos y cambio en propiedades dieléctricas de los mismos. De igual forma, los fenómenos de degradación y deterioro están relacionados con variables que siguen su evolución y que evalúan ya sea cambios graduales en las propiedades intrínsecas de los materiales o incrementos en los niveles o en la rata de formación de subproductos de los mismos fenómenos de deterioro.

Una vez identificados los modos de falla de más probable ocurrencia en los transformadores y los diferentes estados de desempeño de un equipo se seleccionaron las variables evaluadoras. Estas fueron determinadas no solamente a partir de la experiencia de ISA sino también de otras compañías que también han planteado sus propios esquemas de evaluación de

condición de equipos así como de información tomada de normas y guías internacionales. Dentro del proceso de selección de variables se hizo fuerte énfasis en determinar cualitativa o cuantitativamente la capacidad de cada una de ellas para seguir la evolución de uno o más modos de falla. Asimismo se exploraron nuevas variantes de análisis para variables clásicamente establecidas como predictivas con el fin de tratar de mejorar su efectividad. Estas variantes incluyeron evaluación de tendencias de crecimiento periódicas o totales (referidas a un valor inicial) alternadas con la evaluación de valores puntuales.

De acuerdo con la tabla No 2 y teniendo en cuenta que el análisis de gases disueltos (DGA) permite determinar la existencia y el grado de evolución de un gran número de modos de falla, se determinó la inclusión de variables evaluadoras relacionadas con esta metodología. Las normas internacionales [11] y los criterios establecidos por muchos investigadores [12] relacionados con el análisis DGA están enfocados la mayor parte de las veces a tratar de identificar el tipo de falla que se encuentra en evolución al interior del equipo no siendo tan concienzudos en la discriminación entre estados normales y anormales. Estas normas y guías hacen uso básicamente de dos enfoques:

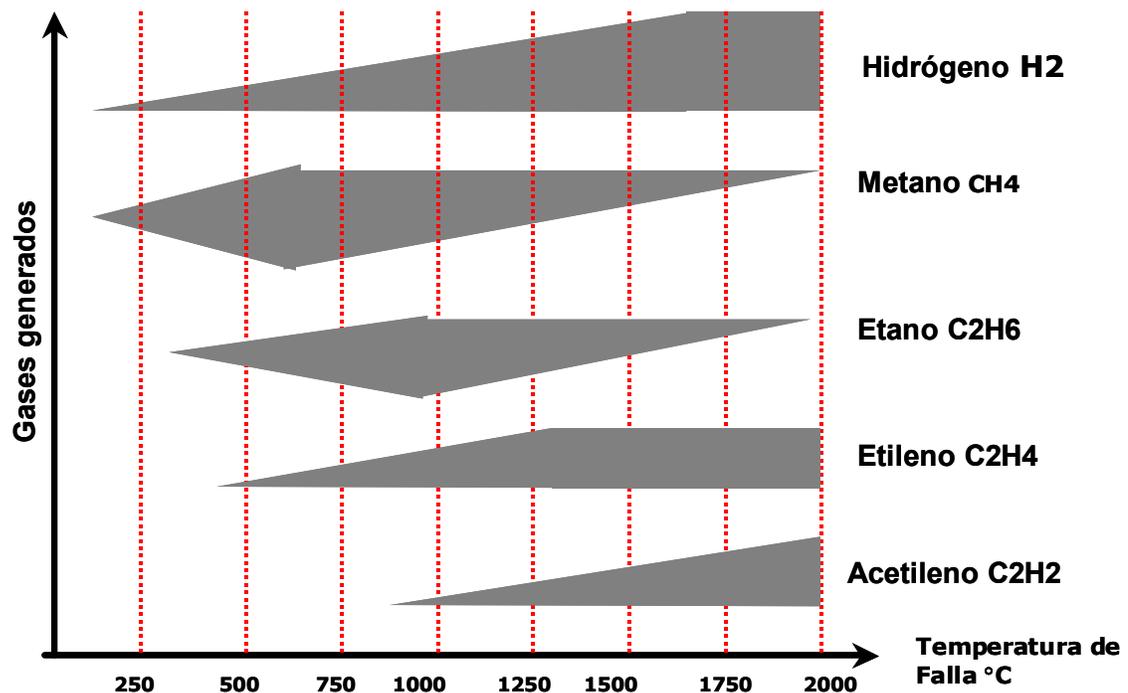
- Determinación de gases claves asociados a modos de falla específicos.
- Uso de relaciones entre gases claves para determinar el modo de falla de un grupo de casos previamente codificados.

El método del gas clave identifica el gas predominante o que se genera en mayor concentración en cada tipo de falla y usa el porcentaje de este gas para diagnosticar la falla interpretando los resultados con base en un conjunto simple de casos previamente establecidos y normalizados. La rata

de formación y la concentración de cada gas esta asociado a la temperatura existente en el punto de falla o avería como lo describe la figura 3.

Por su parte, los métodos basados en relaciones entre gases, evalúan cierto número de relaciones entre los diferentes gases combustibles (el número depende del criterio usado) siempre y cuando estos sobrepasen un valor límite establecido para garantizar la validez del análisis. Finalmente y al igual que en el método de los gases claves, se clasifica el caso bajo estudio de acuerdo con el grado de similitud que presente con otros previamente definidos.

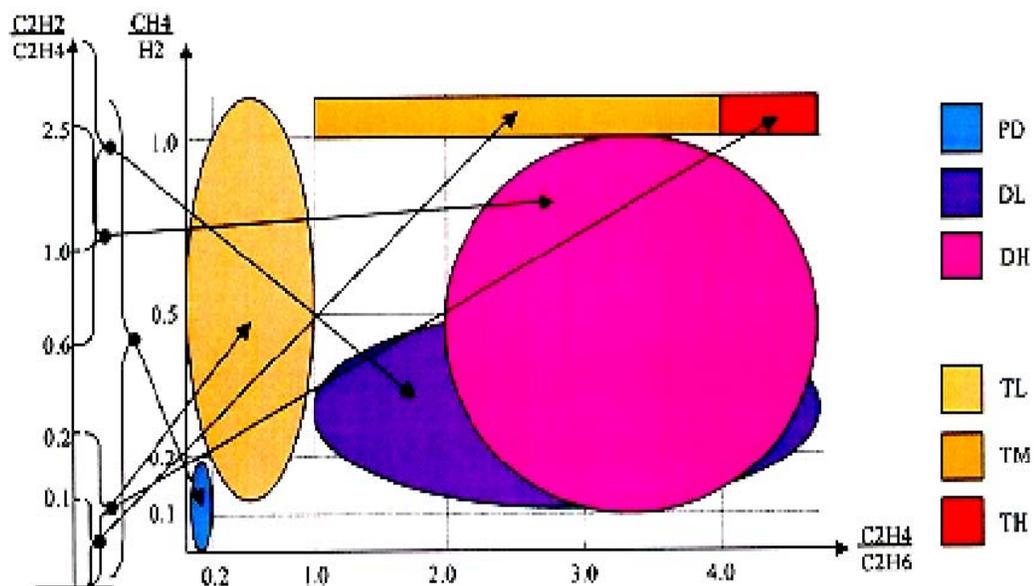
Figura 3. Gases generados durante fallas dieléctricas en aceite aislante.



De acuerdo con algunos investigadores [13], la mayoría de los criterios usados para la identificación de los diferentes modos de falla presentan discontinuidades en los rangos de evaluación de las variables asociadas dando lugar a casos de “no-clasificación”. Como un ejemplo, la figura 4 muestra la sobreposición de zonas de clasificación de fallas típicas

correspondientes a la norma IEC 599 donde se muestran zonas de evidente “no-clasificación”. Con el fin de superar este inconveniente y teniendo en cuenta que algunos gases son generados a mayor temperatura que otros y que por tanto están asociados a modos de falla que revisten mayor criticidad para el transformador y tomando en consideración que durante la evolución de una falla, el contenido de gases se incrementa en la medida que su criticidad aumenta se decidió incluir variables asociadas al crecimiento de gases mas que a su valor puntual como lo establecen la mayoría de las normas.

Figura 4. Zonas de clasificación de modos de fallas basadas en la norma IEC 599.



Dentro de los gases identificados como importantes a monitorear se encuentran:

- Acetileno (C_2H_2): asociado a la presencia de arco o descarga continua que ocasiona temperaturas mayores a $700^\circ C$. La detección de pequeñas cantidades de este gas genera señales de alarma y necesidad de una evaluación de condición mas profunda.
- Hidrógeno (H_2): Su presencia se asocia a fenómenos de “corona” o descargas de baja energía al interior del transformador que comprometen únicamente al aceite. También se han detectado casos en que su generación esta asociada a la presencia de alto contenido de humedad en la celulosa.
- Etileno (C_2H_4): Se genera en mayor proporción durante la descomposición térmica del aceite aislante junto con menores cantidades de metano y etano. Generalmente asociado a fallas con calentamiento puntual o localizado del metal sin compromiso de celulosa o material aislante sólido.
- Metano y Etano (CH_4 y C_2H_6 respectivamente): Aunque esta variable resume el contenido de varios gases es importante a la hora de identificar modos de falla en evolución, sobre todo si estos implican la generación de gases diferentes a los dos anteriormente mencionados y que se asocian generalmente a temperaturas de formación menores como se muestra en la figura 3.

La contaminación de los aislamientos afecta sus propiedades dieléctricas. El factor de potencia es una variable muy importante para determinar su condición ya que mide directamente una de estas propiedades y por tanto fue identificada como una de las variables a incluir en el esquema. De igual forma el contenido de humedad estimado en el aislamiento sólido (papel) permite la identificación de un modo particular de contaminación como es la

humedad y que afecta sensiblemente las propiedades dieléctricas del aislamiento.

Dentro de las variables que siguen los procesos de deterioro y envejecimiento de los aislamientos se identificaron algunas más efectivas que otras teniéndose en cuenta para esto, el cambio en su magnitud y su tiempo de evolución ante la ocurrencia de los modos de falla.

Una vez identificadas las variables evaluadoras e integradas con el aspecto de evaluación correspondiente se obtuvo el esquema general de evaluación el cual se describe gráficamente en la figura 5 y se resume en las tablas No 7 a 9.

Figura 5. Estructura final obtenida para el esquema de evaluación de condición de transformadores y reactores.

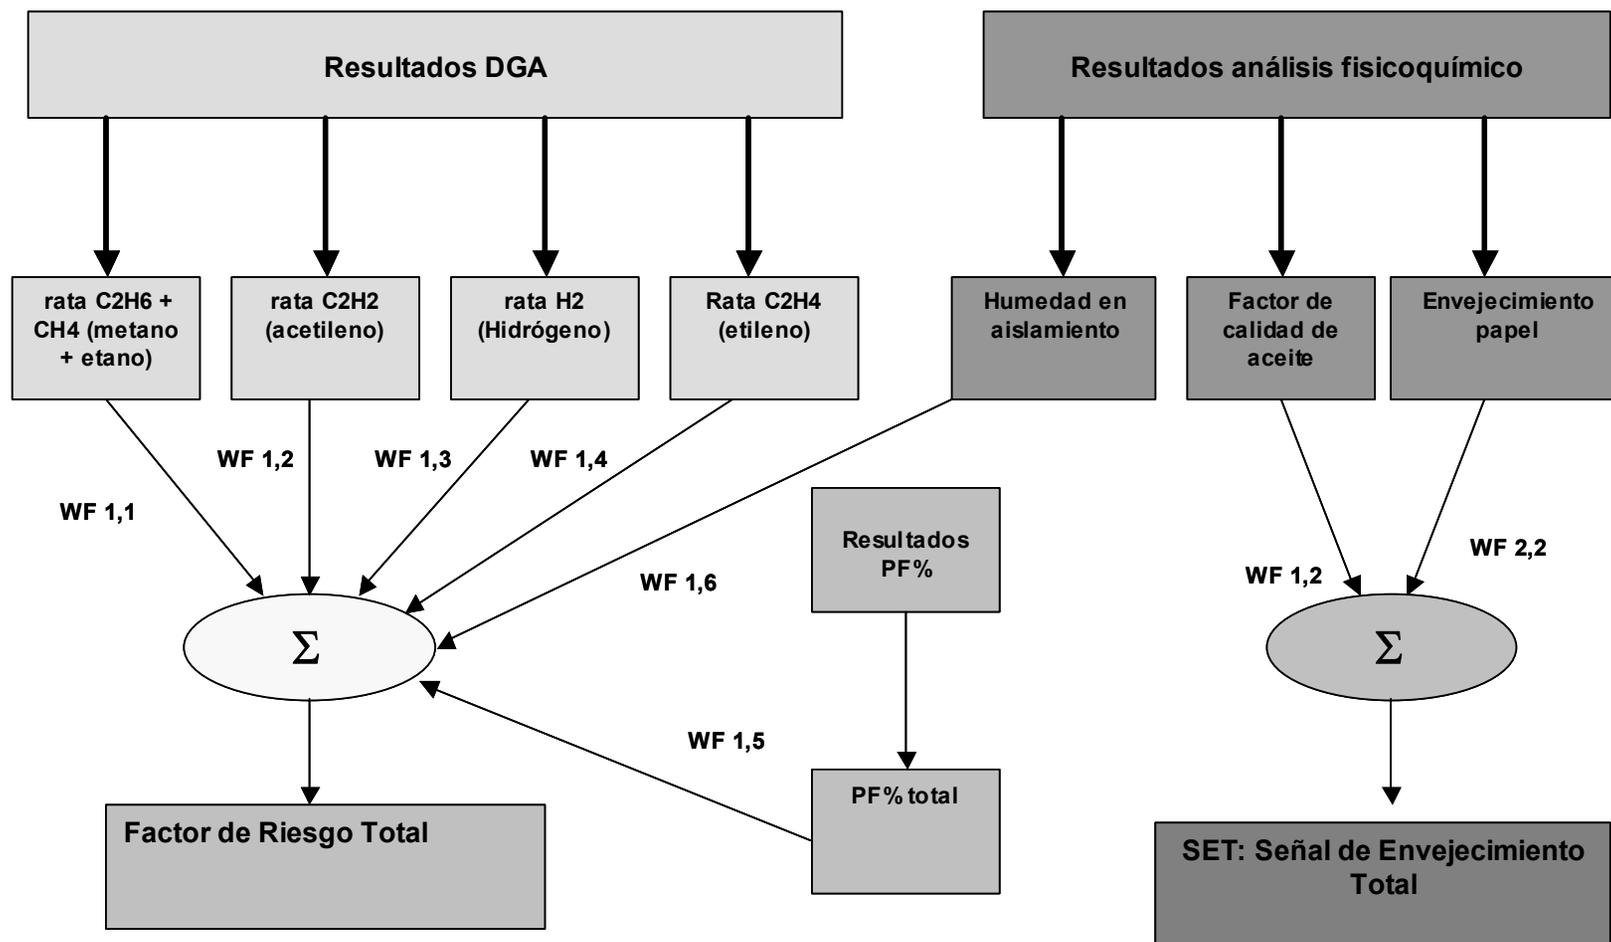


Tabla 3. Resumen de las variables identificadas para inclusión en el esquema de evaluación.

Variable	Descripción	Unidades	Aspecto que evalúa
Rata de crecimiento mensual de gases metano y etano (CH ₄ y C ₂ H ₆ rate).	Resume las ratas mensuales de crecimiento de los gases combustibles metano y etano.	ppm / mes (partes por millón mensuales).	Factor de Riesgo Total (fenómenos de evolución rápida).
Rata de crecimiento mensual de gas acetileno (C ₂ H ₂ rate).	Rata mensual de crecimiento del gas acetileno (C ₂ H ₂).	ppm / mes (partes por millón mensuales).	Factor de Riesgo Total (fenómenos de evolución rápida).
Rata de crecimiento mensual de gas Hidrógeno (H ₂ rate).	Rata mensual de crecimiento del gas hidrógeno (H ₂).	ppm / mes (partes por millón mensuales).	Factor de Riesgo Total (fenómenos de evolución rápida).
Rata de crecimiento mensual de gas Hidrógeno (H ₂ rate).	Rata mensual de crecimiento del gas hidrógeno (H ₂).	ppm / mes (partes por millón mensuales).	Factor de Riesgo Total (fenómenos de evolución rápida).
Contenido de humedad en aislamiento sólido	Mide el porcentaje de humedad que contiene el aislamiento sólido.	%	Factor de Riesgo Total (fenómenos de evolución rápida).
Contenido de compuestos furánicos disueltos en aceite.	Mide el contenido de 2 furfuraldehído en el aceite para estimar el grado de polimerización promedio de la celulosa que compone el aislamiento.	ppb (partes por billón en aceite).	Señal de Envejecimiento Total (fenómenos de evolución lenta).
Factor de calidad del aceite (relación tensión interfacial vs número de neutralización).	Mide la relación entre la tensión interfacial (dinas / cm) y el número de neutralización (mg de KOH) para determinar su grado de deterioro medido a través de la acidez (mg de KOH) y la pérdida de propiedades fisicoquímicas (tensión interfacial).	(dinas / cm) / mg de KOH	Señal de Envejecimiento Total (fenómenos de evolución lenta).
Factor de potencia de aislamientos.	Integra el factor de potencia de todos los aislamientos que posea el equipo, ponderándolos de acuerdo con el grado de exigencia en servicio (tensión de operación, tecnología de construcción, etc).	%	Factor de Riesgo Total (fenómenos de evolución rápida).

2.2 OBTENCIÓN DE CRITERIOS DE EVALUACIÓN

Como ya se mencionó, los criterios de evaluación son aplicados a cada variable para obtener calificaciones individuales las cuales serán ponderadas posteriormente a través de “superreglas” e integradas en la calificación de cada uno de los aspectos seleccionados. Los criterios fueron obtenidos realizando un análisis estadístico descriptivo de la población total de datos almacenados en el Sistema Integrado de Información SAP/R3 y en la antigua base de datos de mantenimiento SIMPES desarrollada bajo lenguaje ACCESS. Los pasos seguidos para la obtención de estos criterios fueron:

- Elaboración de archivos fuente con datos de la variable a evaluar (valor puntual, valor del incremento histórico y fecha de prueba) asociados con información sobre tipo constructivo, fabricante, número interno de identificación y tiempo de servicio de los equipos.
- Aplicación de ciclos sucesivos de normalización y estandarización para filtrar datos anómalos o que se encuentran fuera del comportamiento normal de la población o línea base [14], [15].
- Evaluación de la influencia de factores particulares como aspectos constructivos y tiempo de servicio sobre las variables estadísticas resumen finalmente obtenidas para cada población de interés.
- Construcción de los diferentes rangos de evaluación tomando como base los resultados obtenidos para las variables resumen.
- Verificación de efectividad del criterio obtenido evaluando casos previamente conocidos y analizados por otros expertos con diagnóstico final comprobado.

La evaluación de la influencia de variables de tipo constructivo y del tiempo de servicio es importante para determinar si se debe elaborar un solo criterio general o varios particulares. Como ejemplo, en la figura 6 se muestra el comportamiento de los valores de la media y la desviación estándar de la rata de generación mensual de gases combustibles totales (TDGC rate) tanto para la población general de transformadores como para diferentes poblaciones particulares discriminadas por su tiempo de servicio y tipo constructivo. Las tablas No 10 a 12 relacionan los factores identificados como de posible influencia en la determinación de criterios particulares de evaluación para subpoblaciones o familias de equipos. Asimismo identifica factores y fuentes de error que pueden afectar los resultados de la evaluación parcial de cada variables generando diagnósticos erróneos.

Figura 6. Comportamiento de las principales variables estadísticas resumen para la rata de generación mensual de gases combustibles (TDGC rate).

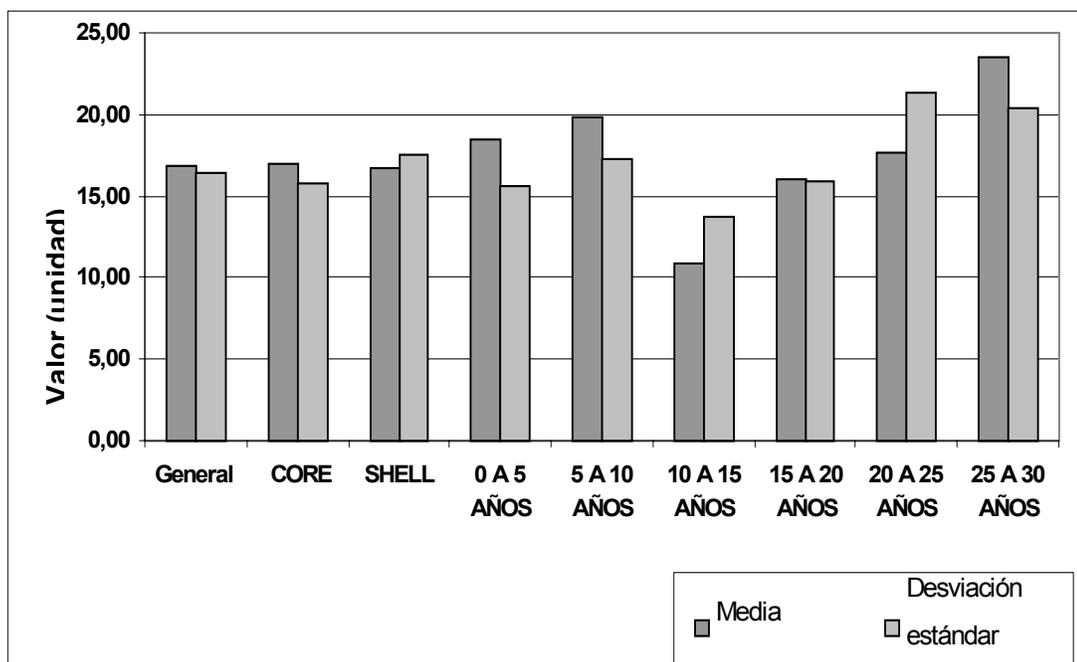


Tabla 4. Identificación de factores generadores de criterios particulares de evaluación o que dan lugar a errores en el diagnóstico para subpoblaciones de equipos

Variable evaluadora	Factores generadores de criterios particulares o de error en diagnóstico	Resultados de evaluación
Ratas de crecimiento mensual de gases	Comunicación entre cambiador de tomas y cuba que permite traspaso de gases combustibles (falsa alarma). Pinturas alquídicas usadas al interior de los equipos que al descomponerse generan gases combustibles (falsa alarma). Tipo constructivo del transformador (core o shell). El tipo shell tiene una relación papel / aceite mayor. Tiempo de servicio de la unidad (se espera mayor generación de gases al final de la vida útil). Tipo de transformador (unidad de generación, transmisión, servicios auxiliares). Los de generación trabajan a mayor carga promedio por tanto generan mas gases.	Aunque existen pequeñas variaciones en los valores de las variables resumen estadísticas obtenidas para diferentes subpoblaciones de transformadores (clasificadas por tiempo de servicio y tipo constructivo) no se justifica la inclusión de criterios de evaluación particulares.
Factor de potencia de aislamientos	Tensión de servicio (mayor tecnología y calidad involucrada a mayores tensiones). Materiales aislantes diferentes a papel, cartón y madera usados por fabricantes. Fecha de fabricación (criterios antiguos de evaluación de resultados mas conservadores que os actuales). Tecnología de fabricación (Nivel de secado de papel obtenido en fábrica determina contenido de humedad y a su vez los valores iniciales de factor de potencia de aislamientos afectando criterios de evaluación de tendencias).	Establecidos factores de ponderamiento para cada devanado (alta tensión, media tensión, baja tensión) para resumir las variables parciales en una sola (factor de potencia de devanado). Establecidos criterios particulares aislamiento baja tensión de transformadores tipo shell año 1985. Posible uso de material aislante diferente a papel en la construcción de este devanado influencia los valores.
Factor de calidad del aceite	Procesos de regeneramiento de aceite no efectivos (con equipo desenergizado) pueden ocasionar rápida degradación de propiedades y aceleración de degradación.	No se observaron comportamientos particulares de poblaciones de equipos que ameriten creación de criterios particulares.
Contenido de humedad en aislamiento sólido	Baja carga del transformador (temperaturas de devanados por debajo de 40°C) no asegura consecución de equilibrio en el proceso de difusión de humedad y ocasiona subestimación de su contenido.	Se encuentra en proceso de implementación un procedimiento para lograr equilibrio térmico en el proceso de difusión de humedad. Se decidió implementar criterios con base en norma y artículos.
Contenido de compuestos furánicos disueltos en aceite	Existencia de papel termo estabilizado (la rata de degradación de este papel es mucho menor que la del papel KRAFT convencional y los niveles de furanos generados son menores). Procesos de regeneramiento de aceite con arcillas activadas (Tierra Fuller) eliminan el contenido de compuestos furánicos disueltos debiendo esperar 18 meses hasta que se recuperen nuevamente los niveles.	Aunque solo se ha confirmado el uso de papel termoestabilizado en un grupo de reactores japoneses de línea de 500 kV de reciente adquisición (1998), se sospecha de su uso en un lote de equipos del mismo fabricante de anterior adquisición (1985). Se decidió usar criterios de evaluación para papel KRAFT convencional debido al poco tiempo de servicio de los equipos en los cuales se confirmo el uso de papel termoestabilizado.

Los criterios de evaluación fueron ajustados tomando como base los valores obtenidos de las variables resumen estadísticas después de la aplicación de ciclos sucesivos de normalización y estandarización. Posteriormente fueron comparados con criterios establecidos por asociaciones mundiales de ingenieros (IEEE), asociaciones de fabricantes y usuarios (CIGRE) y compañías fabricantes de equipos de pruebas y prestadores de servicios (Doble Engineering Co) encontrándose la mayoría de las veces que los criterios obtenidos eran más estrictos que los de las normas y guías referidas, especialmente en lo que hace referencia a gases combustibles, como se describe en las tablas 13 a 15. El tener los valores límite más ajustados permite una más temprana detección de modos de falla de incipiente evolución.

Tabla 5. Resumen comparativo de criterios y valores límite obtenidos para las diferentes variables evaluadoras.

Variable calificadora	Criterio establecido por	Valor límite	Valor límite de cuestionamiento obtenido con el estudio.
Rata de crecimiento mensual de gases metano y etano (CH ₄ y C ₂ H ₆ rate)	IEEE C 57.104-1991 IEC 599.	300 ppm / mes; 720 ppm (puntual) 500 ppm (valor puntual)	2.92 ppm / mes
Rata de crecimiento mensual de gas acetileno (C ₂ H ₂ rate)	IEEE C 57.104-1991 IEC 599	ppm / mes; 35 ppm (puntual) 20 ppm (valor puntual)	0.416 ppm / mes
Rata de crecimiento mensual de gas etileno (C ₂ H ₄ rate)	IEEE C 57.104-1991 IEC 599	300 ppm / mes; 100 ppm (puntual). 100 ppm (valor puntual)	0.65 ppm / mes
Rata de crecimiento mensual de gas Hidrógeno (H ₂ rate)	IEEE C 57.104-1991 IEC 599	300 ppm / mes; 100 ppm (puntual). 100 ppm (valor puntual)	2.747 ppm / mes
Factor de potencia de aislamientos.	Doble Engineering Co IEEE C57.12.90	0.5% (todos los aislamientos) 0.7% (todos los aislamientos)	0.40% (aislamientos alta vs baja y alta vs. tierra); 0.54% (aislamiento baja vs. tierra).
Contenido de humedad en aislamiento sólido.	V.Sokolov	15 ppm a 60°C	2.5% de contenido en papel (límite máximo)
Contenido de compuestos furánicos disueltos en aceite.	SD Myers [17] Doble Engineering Co	250 ppb (límite máximo de cuestionamiento). 10000 ppb.	No se ha establecido criterio propio por ser de reciente implementación la tecnología.
Factor de calidad del aceite (relación tensión interfacial vs. número de neutralización).	IEEE C57.106	Tensión interfacial: 30 dinas/cm Número de neutralización: 0.1 mg KOH	Los criterios actualmente establecidos son suficientes. No se planteó la generación de criterios propios.

2.3 OBTENCIÓN DE FACTORES PONDERADORES DE VARIABLES CALIFICADORAS Y DE REGLA EVALUADORA DE ASPECTOS

Una vez seleccionadas las variables evaluadoras y obtenidos sus criterios de evaluación se procedió a desarrollar una función integradora para cada uno de los aspectos previamente seleccionados: factor de riesgo total y señal de envejecimiento total, que permitiera ponderar los aportes de cada una de las variables de acuerdo a su importancia. Esta importancia fue determinada a través de consultas con varios analistas de mantenimiento con suficiente y probada experiencia en la realización del proceso de evaluación de condición de equipos. Dentro de los aspectos tenidos en cuenta para determinar el grado de importancia de la variable figuraban:

- Grado de reversibilidad del modo o modos de falla de probable identificación por la variable.
- Importancia del elemento o parte afectada por el modo de falla.
- Tiempo y costos estimados para la reparación de la avería ocasionada por el modo de falla.

Los anteriores aspectos ayudaron a determinar en gran parte los factores de ponderación de cada variable los cuales fueron incorporados como coeficientes de cada una de ellas en las funciones integradoras y/o como valores límite de la calificación parcial superior e inferior que cada una suministraba. Las funciones integradoras incluyeron funciones lógicas, matemáticas y factores de ponderación. Dado el carácter de confidencialidad que ISA le ha dado a este y otros desarrollos no es posible mostrar en detalle las expresiones evaluadoras obtenidas. En cambio, es posible mostrar cualitativamente el grado de importancia identificado para cada variable lo cual se describe en la tabla No 6.

Tabla 6. Grado de importancia identificado para cada una de las variables evaluadoras seleccionadas.

Variable	Grado de importancia	Aspecto evaluado
Rata de crecimiento mensual de gases metano y etano (CH ₄ y C ₂ H ₆ rate)	Medio Alta	Factor de Riesgo Total
Rata de crecimiento mensual de gas acetileno (C ₂ H ₂ rate)	Alta	
Rata de crecimiento mensual de gas etileno (C ₂ H ₄ rate)	Alta	
Rata de crecimiento mensual de gas Hidrógeno (H ₂ rate)	Medio Alta	
Factor de potencia de aislamientos	Medio Medio	
Contenido de humedad en aislamiento sólido	Medio Bajo	
Contenido de compuestos furánicos disueltos en aceite.	Alto	Señal de Envejecimiento Total
Factor de calidad del aceite (relación tensión interfacial vs número de neutralización).	Medio Bajo	

3. IMPLEMENTACIÓN DEL ESQUEMA DE EVALUACIÓN DE CONDICIÓN DE TRANSFORMADORES Y REACTORES USANDO TÉCNICAS CLÁSICAS Y DE INTELIGENCIA ARTIFICIAL

El problema básico que se plantea en este trabajo de investigación implica la evaluación de nueva información a partir del conocimiento de información previa y representada en casos conocidos y previamente evaluados. Su solución puede ser conseguida a través de la aplicación de varias técnicas algunas ya clásicas como la interpolación y otras de mas reciente advenimiento como lo son las basadas en inteligencia artificial y sistemas expertos. En este capítulo se describen y fundamentan ambos planteamientos.

3.1 ANTECEDENTES DE LA APLICACIÓN DE INTELIGENCIA ARTIFICIAL AL PROCESO DE ANÁLISIS DE CONDICIÓN DE TRANSFORMADORES DE POTENCIA

Desde hace algún tiempo, se ha venido incorporando diferentes estrategias de inteligencia artificial a los esquemas de evaluación de condición de equipos, más específicamente al de los transformadores de potencia. Los principales desarrollos han sido enfocados a la clasificación correcta del modo de falla en probable evolución en el equipo de acuerdo con los casos previamente establecidos en las normas IEEE C57.104-1991 e IEC 599 a partir del contenido de gases disueltos en aceite, usando principalmente las relaciones entre gases claves [18]. Otros más sofisticados han tratado de desarrollar esquemas de evaluación de condición integrales incorporando información de variables adicionales a contenidos de gases. [19]. Uno de los esquemas quizá mejor concebido y planteado es el desarrollado por Wang [13] quien incorpora

clasificadores de normalidad / anormalidad de la condición integral del equipo como paso previo a la determinación y clasificación del tipo de falla. La tabla No 6 resume algunos de estos desarrollos y las técnicas usadas en su implementación. Dentro de las técnicas mas usadas se observan los conjuntos difusos y los mapas autoorganizados las cuales son muy consistentes con las características del problema abordado como son la necesidad de clasificación y la identificación de patrones de comportamiento y obtención de criterios ajustados y particulares de evaluación.

Tabla 74. Resumen de esquemas de evaluación de condición de transformadores implementados con herramientas de inteligencia artificial.

Autor	Variables evaluadas	Técnicas Usadas	Comentarios
Z. Wang [13]	DGA, Propiedades Físicoquímicas de aceite, Compuestos Furánicos y DP	Perceptrón MultiCapa (MLP), Vector de Quantización (LVQ), Redes Neuronales, lógica difusa.	El esquema propuesto tiene incluido módulo clasificador normal/anormal. Incluye rutina de diagnóstico de condición de cambiadores bajo carga (OLTC's)
A. Schenk [20]	DGA, Propiedades Físicoquímicas de aceite, Compuestos Furánicos y DP, Pruebas Eléctricas	Mapas de Auto-organización	Diseñado para monitoreo en línea de parámetros y evaluación con base en resultados almacenados en base de datos.
K.Obu-Cann [21]	Temperaturas de aceite, devanados y ambiente y carga del transformador	Mapas de Auto-organización	Predice temperaturas de aceite en transformadores de distribución.
Petterson and Fantana [22]	DGA, cargabilidad, aspectos de diseño y construcción, pruebas eléctricas.	Conjuntos Difusos	Clasifica la condición de las unidades de acuerdo con los criterios establecidos.
McGrail, Gulski, Allan y otros [23]	DGA (Análisis Gases Disueltos)	Mapas autoorganizados Kohonen	Traza e identifica la trayectoria del comportamiento de los gases sobre un mapa clasificatorio.
Roizman y Davydov [24]	Dinámica de la humedad al interior de los aislamientos, Determinación de capacidad de carga de unidades.	Algoritmos Neuro-difusos	Predice el contenido de humedad del aislamiento sólido a partir del monitoreo de la humedad en el aceite.
Kalid y Zain [25]	DGA (Análisis Gases Disueltos) y Pruebas Eléctricas	Conjuntos difusos	Detecta tempranamente la aparición de fallas y diagnostica la condición del equipo.
Thang, Aggarwal, Mc Grail y Esp [26]	DGA	Análisis estadísticos y minería de datos usando mapas autoorganizados (SOM).	Obtiene identificación gráfica de zonas de falla a partir de varios criterios de evaluación usando SOM.
Mofizul, Wu y Ledwich [19]	DGA	Lógica Difusa	Mide el grado de similitud entre los vectores de datos y vectores patrón de casos típicos.

3.2 REDES NEURONALES ARTIFICIALES

Se estima que el cerebro humano contiene más de cien mil millones (10^{11}) de neuronas y (10^{14}) sinapsis o conexiones en el sistema nervioso humano. Estudios sobre la anatomía del cerebro humano concluyen que hay más de 1000 sinapsis a la entrada y a la salida de cada neurona. Es importante notar que aunque el tiempo de conmutación de la neurona (unos pocos milisegundos) es casi un millón de veces mas lento que en los actuales elementos de las computadoras, las neuronas tienen una conectividad miles de veces superior que estas.

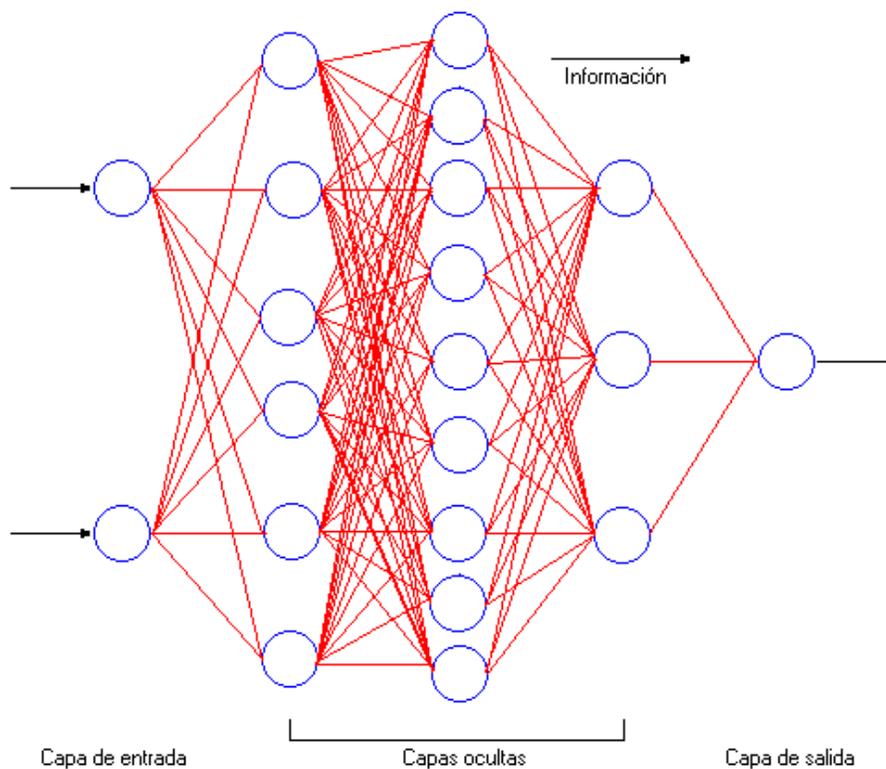
Las redes neuronales artificiales son un conjunto de elementos simples, fuertemente interconectados y de procesamiento paralelo (ver figura 7). Su mecanismo para procesar la información se encuentra inspirado en la naturaleza cerebral, lo que implica una capacidad de aprendizaje a partir de la experiencia. Las redes neuronales hacen parte de la inteligencia artificial, donde ocupan lugar privilegio, gracias a su potencial aplicación en múltiples áreas.

3.2.1 Características. Dentro de las características mas importantes de las redes neuronales figuran:

- **Aprendizaje Adaptativo.** Significa que son capaces de aprender a realizar tareas a partir de datos representativos del problema. Las redes neuronales son sistemas dinámicos autoadaptativos, ya que sus elementos de proceso poseen la capacidad de autoajustarse, según sea necesario. Las redes neuronales tienen la capacidad de estar en constante evolución para lograr una mejor adaptación a nuevas condiciones, aspecto que les imprime un carácter dinámico.
- **Autoorganización.** Capacidad de organizar la información adquirida durante el aprendizaje, entre sus elementos de proceso. La autoorganización de la

información le permite a las redes neuronales artificiales generalizar, siendo la generalización la capacidad de responder adecuadamente ante datos nunca presentados en el entrenamiento, permitiendo inclusive que el sistema responda en forma aceptable aún cuando la información de entrada se encuentre incompleta.

Figura 7 Red Neuronal Artificial



- Tolerancia a fallos. En tolerancia a fallos se deben considerar dos aspectos. El primero hace referencia a la calidad de la información de entrada la cual puede estar afectada por ruido, distorsión o estar incompleta. Las redes neuronales han demostrado que son capaces de aprender a reconocer patrones con estas características. Este tipo de tolerancia se llama tolerancia a fallos con respecto a datos. El segundo aspecto se relaciona con la

continuidad de la tarea aún cuando cierta parte de la red se encuentre destruida. Lo anterior se explica por el hecho que la información adquirida en el entrenamiento, se encuentra distribuida entre las conexiones de los elementos de proceso.

3.2.2 Aplicaciones. Las características anteriores han permitido aplicar la teoría las redes neuronales con éxito en áreas como el control y modelado de sistemas dinámicos no lineales. En la tabla 20, son presentadas algunas de las aplicaciones de las redes neuronales artificiales.

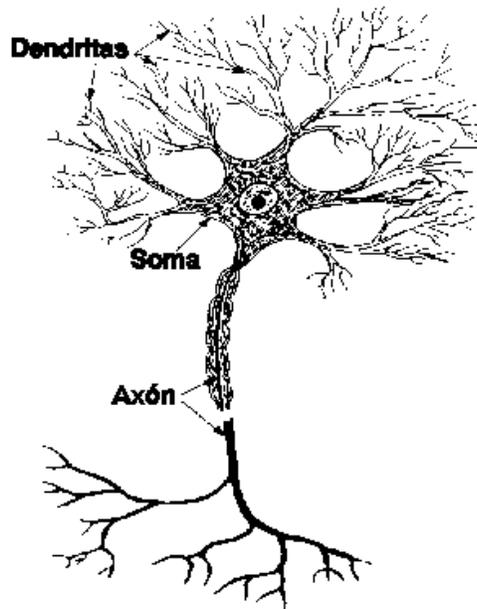
Tabla 8. Algunas aplicaciones de las redes neuronales artificiales.

DISCIPLINA	APLICACIONES
Biología	Obtención de modelos de la retina y el cerebro.
Empresas	Evaluación de formaciones geológicas y petrolíferas, reconocimiento de caracteres manuscritos, optimización de plazas y horarios en líneas de vuelos.
Medio Ambiente	Previsión del clima, análisis tendencias y patrones.
Finanzas	Previsión de la evolución de precios, valoración de riesgo en créditos, interpretación de firmas.
Manufactura	Control de robots, inspección de calidad.
Medicina	Diagnóstico y tratamiento a partir de síntomas y/o datos analíticos, lectores de rayos X, predicción de reacciones adversas a medicamentos, analizadores del habla.
Militares	Creación de armas inteligentes, clasificación de señales de radar, reconocimiento de patrones y direccionamiento de misiles balísticos.

3.2.3 Modelo Biológico. Las redes neuronales artificiales fueron concebidas en un intento de emular el funcionamiento del sistema nervioso. Recordemos que las neuronas biológicas son células cuya principal característica es su gran capacidad de comunicación, existiendo aproximadamente 10^{11} neuronas y más de 10^{14} conexiones en el cerebro humano.

La figura 8 representa una neurona biológica. En ella se pueden distinguir: un cuerpo o soma (generalmente esférico), una rama principal conocida como axón y otras más cortas, llamadas dendritas, el axón a su vez también se ramifica, en las terminales axónicas.

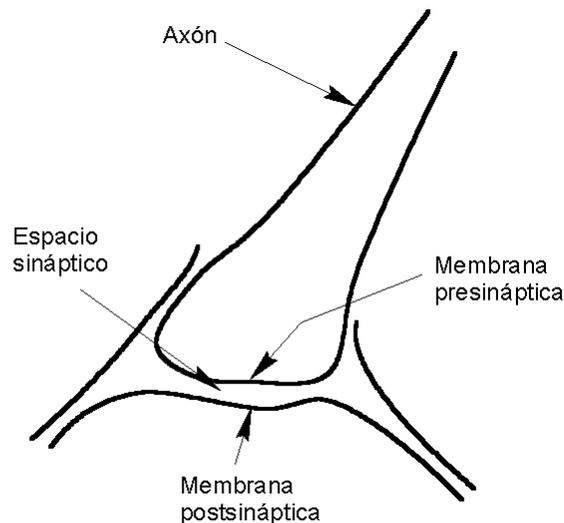
Figura 8 Neurona biológica y sus principales partes



El procesamiento de la información en el modelo biológico inicia cuando las dendritas recogen las señales procedentes del exterior o de otras neuronas y la llevan al cuerpo de la neurona, donde son procesadas y posteriormente se emite

una respuesta o señal de salida, que es transportada a través del axón. La señal de salida es transmitida a las otras células o sistemas con los cuales la neurona se encuentra conectada, por medio de las llamadas terminales axónicas. El punto de unión entre un terminal axónica y una dendrita (ver figura 9), se conoce como sinapsis. Existen dos tipos de sinapsis; la excitadoras y las inhibitoras, las cuales causan efectos contrarios (excitación o reposo), sobre la neurona receptora. El nuevo estado y la señal de salida de la neurona, depende del estado de activación y de la suma de las señales recibidas.

Figura 9. Sinapsis en la Neurona Biológica



3.2.4 Elementos de una red neuronal artificial. Dentro de los elementos principales que constituyen una red neuronal artificial se encuentran:

- **Conexiones.** Son los canales por donde viajan las señales entre neuronas. Es en las conexiones donde se encuentra almacenada la experiencia de la red. El sentido de flujo de la información puede ser uni o bidireccional, dependiendo del tipo de red. A cada conexión se le asocia un parámetro llamado peso (equivalente a la sinapsis en el modelo biológico); se representa

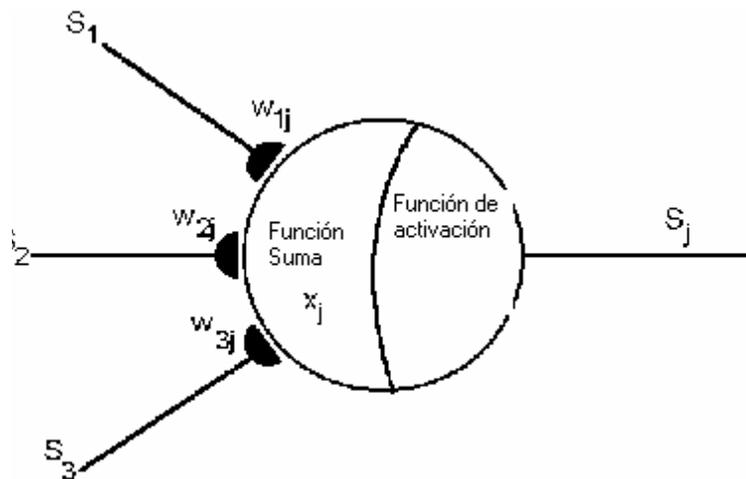
por w , y su función es amplificar o atenuar las señales que pasan a través de la conexión. Los pesos pueden tomar valores positivos (conexión excitadora), negativos (conexión inhibitoria), y cero que indica que no hay conexión. Durante la fase de entrenamiento los pesos son modificados en forma sistemática mediante la regla de aprendizaje, siendo el entrenamiento el proceso donde se presentan a la red los ejemplos que le permitirán adquirir la experiencia necesario para realizar en forma satisfactoria su tarea.

Las redes neuronales se pueden clasificar según el tipo de conexiones, en:

- Redes con conexiones hacia adelante: la información en estas redes, siempre viaja desde la capa de entrada hasta la de salida, pasando por las capas ocultas.
- Redes con conexiones hacia adelante / atrás: en ellas existen conexiones hacia adelante y hacia atrás, que permite el flujo de las señales en ambas direcciones.
- Redes con conexiones laterales: sus elementos de proceso presentan conexiones hacia el mismo nivel o capa. En este tipo de red a su vez se presentan dos tipos de conexiones, la primera son las llamadas conexiones autorrecurrentes, existentes cuando la salida del elemento de proceso es alimentada en su entrada. El segundo tipo son las conexiones no autorrecurrentes, aquellas donde la señal de salida es alimentada a otro elemento de proceso de la misma capa.
- Neuronas artificiales. También llamadas elementos de proceso (ver figura 10). Su función es simple, y consiste en recoger señales provenientes de su entorno, procesarlas y entregar una señal de salida. El origen y destino de las señales de las neuronas, permiten clasificarlas en:

- Neuronas de Entrada: Son aquellas que reciben señales del exterior y la llevan hacia el interior de la red, conformando la capa de entrada. Las señales generalmente provienen de sistemas sensoriales.
- Neuronas Ocultas: También llamadas de proceso, son las que procesan las señales. Las neuronas ocultas no tienen contacto directo con el exterior y se ubican en capas ocultas o intermedias de la red.
- Neuronas de Salida: Son las encargadas de recoger la información del interior de la red y brindar un resultado, conformando la capa de salida.

Figura 10 Neurona artificial y sus partes



Las neuronas artificiales, al igual que las biológicas presentan un estado de activación, que también depende de la suma de las señales que recibe. Existe una función de salida, que transforma el estado de activación $a_i(t)$, de la neurona i -ésima, en una señal de salida y_i , que es enviada a las otras neuronas con las que tiene conexión. Para un mayor entendimiento de la mecánica del

funcionamiento de las redes neuronales, es necesario es definir conceptos como: regla de propagación, estado de activación, función de activación, función de salida y regla de aprendizaje.

3.2.5 Regla de Propagación. La forma en que se combinan todas señales que entran a la j -ésima con sus respectivos pesos, se llama regla de propagación. La entrada total a la neurona j -ésima es:

$$Net_j = \sum_i y_i W_{ji} \quad (1)$$

donde, W_{ij} representa el valor del peso de la conexión de la neurona i a la j .

3.2.6 Estado de Activación. En cualquier instante todas las neuronas de la red se encuentran en cierto estado, que puede ser de reposo o de excitación. Los valores que toman los estados de activación pueden ser: continuos, cuando los valores se encuentran entre los rangos $[0,1]$ o $[-1,1]$ así como también discretos. En este último caso se utilizan valores binarios, donde el estado de activación se indica por el uno, y el estado de reposo por el cero. El estado de activación de una red para un instante t , se representa así:

$$A(t) = (a_1(t), a_2(t), \dots, a_i(t), \dots, a_n(t)) \quad (2)$$

donde, $a_i(t)$ representa el estado de activación de la neurona i -ésima, en el instante t .

3.2.7 Función de Activación. El estado de activación de cualquier neurona en el tiempo $t+1$, depende de su estado de activación en el tiempo t , y de la entrada total de la neurona (calculada mediante la regla de propagación), por lo tanto el nuevo estado de activación de la neurona j -ésima es:

$$a_j(t+1) = F(a_j(t), Net_j) \quad (3)$$

Normalmente la función de activación no se encuentra en el origen del eje que representa el valor de la entrada neta, este desplazamiento se conoce como umbral de la neurona (θ), y es diferente par cada neurona; por lo tanto la ecuación anterior se convierte en:

$$a_j(t+1) = F(a_j(t), Net_j - \theta_j) \quad (4)$$

Existen diferentes tipos de función de activación, aquí solo se considera la función de activación lineal y la función de activación sigmoial.

$$a_j(t+1) = Net_j - \theta_j \quad (5)$$

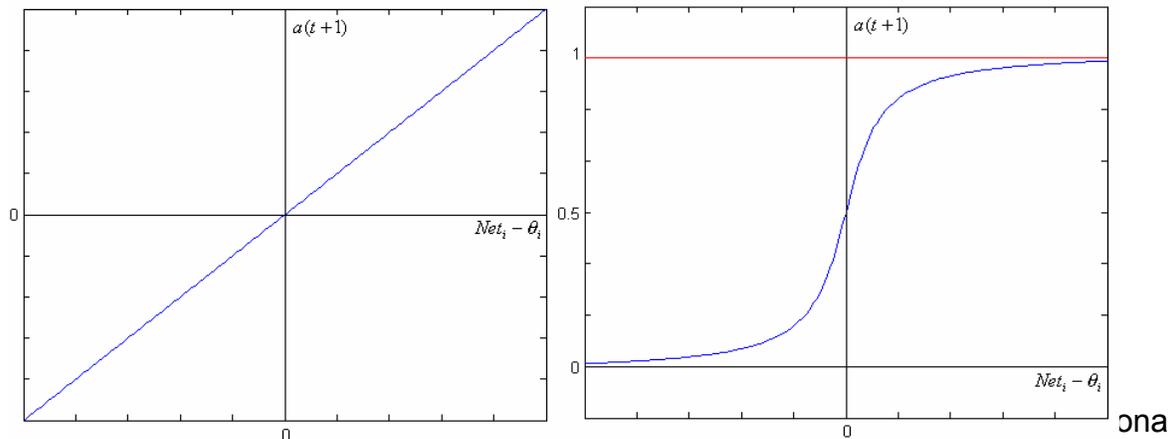
La utilización de una función de activación lineal, permite que el estado de activación sea cualquier número real.

Función de activación sigmoial: es una función continua, que presenta un valor asintótico menor y otro superior. Una función de activación sigmoial, garantiza que el estado de activación es un real, determinado por la siguiente expresión:

$$a_i(t+1) = \frac{1}{1 + e^{-(net_i - \theta_i)}} \quad (6)$$

La figura 11, muestra la función de activación lineal y sigmoial respectivamente.

Figura 11 Funciones de activación lineal y sigmoideal respectivamente



j , en el tiempo $t+1$, y emitir una señal de salida (y_j), hacia las neuronas con las que se encuentra conectada. La función de salida se puede expresar como:

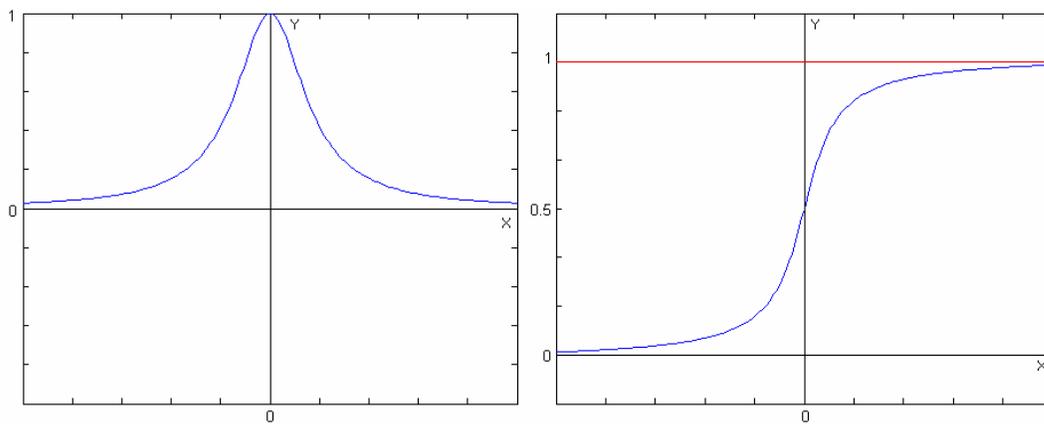
$$y_j(t+1) = f(a_j(t+1)) \quad (7)$$

Existen diferentes tipos de funciones de salida de las cuales se describen a continuación dos de las más comunes como son:

- **Función sigmoideal:** Es una función continua, con incremento monótonico, cuyas derivadas siempre están próximas a cero, para valores grandes (positivos o negativos); además tiene bien definido el límite superior e inferior, características que le permiten brindar buenos resultados. La existencia de un límite superior e inferior, garantiza que el resultado generalmente se encuentre a uno u otro lado del sigmoide.
- **Función gaussiana.** La posibilidad de modificar el centro y la anchura de la función, las hace más adaptativas que las sigmoideales. Las redes neuronales que en sus neuronas utilizan funciones de transferencia gaussiana, suelen necesitar menos capas de neuronas ocultas, lo cual reduce el tiempo de

entrenamiento. En la figura 12, son presentadas las funciones sigmoideal y gaussiana.

Figura 12. Funciones de transferencia gaussiana (izq) y sigmoideal (der).



3.2.8 Regla de Aprendizaje. En las redes neuronales la regla de aprendizaje es el mecanismo de evolución de los pesos de la red durante el entrenamiento, consecuencia de la interacción con los diferentes ejemplos que describen la tarea a aprender. Existen dos mecanismos de aprendizaje; aprendizaje supervisado y no supervisado. El mecanismo de aprendizaje retropropagación es supervisado.

3.2.9 Redes con aprendizaje supervisado. El aprendizaje supervisado se caracteriza por la existencia de un agente externo llamado supervisor, que controla el proceso de aprendizaje. La función del supervisor es comparar la salida generada por la red y salida sistema (deseada), para establecer el nivel de error cometido por la red. Si el nivel de error sobrepasa un mínimo

preestablecido, se procede a la modificación de los pesos hasta lograr que el error llegue al valor deseado. Para el entrenamiento de las redes con aprendizaje supervisado se requiere alimentar la red con vectores que contengan información tanto de la entrada como de la salida del sistema (A_i, B_i) , ya que el supervisor utiliza la salida del sistema (B_i) , para establecer el error cometido por la red. En el mecanismo de aprendizaje no supervisado, desaparece el supervisor.

Las redes neuronales que requieren para su entrenamiento vectores con información de la entrada y salida del sistema se denominan, redes heteroasociativas. Las llamadas redes autoasociativas, aprenden vectores de la forma: $A_1, A_2, A_3, \dots, A_n$, de tal modo que en la fase de operación cuando se le presente una información la red responde con el dato almacenado más parecido.

Las redes neuronales pueden manejar tanto información binaria como análoga (representación de la información de entrada y salida), entonces aparece otra clasificación las redes neuronales. Según el tipo de información que reciben y entregan las redes, son clasificadas en:

- Redes Continuas: son aquellas que solamente reciben señales análogas en su entrada y responden con información del mismo tipo.
- Redes Binarias: La información que entra y sale de la red es binaria.
- Redes Híbridas: Este tipo de redes, maneja información análoga en su entrada y binaria en su salida.

3.2.10 Redes con aprendizaje no supervisado. Para los modelos de aprendizaje no supervisado, el conjunto de datos de entrenamiento consiste solo en los patrones de entrada, por lo tanto, la red es entrenada sin el beneficio de un

maestro. La red aprende a adaptarse basada en las experiencias recogidas de los patrones de entrenamiento anteriores.

3.2.11 Desventajas de las Redes Neuronales. Las redes neuronales, son conocidas como modelos de caja negra, por la dificultad que implica convertir su experiencia en representaciones de conocimiento tradicionales porque el mismo se encuentra representado en una matriz numérica (pesos).

Otra desventaja es la posibilidad de asentamiento en mesetas o mínimos locales, que no brindan un resultado satisfactorio en términos del error.

Una vez establecidos los fundamentos teóricos básicos a continuación se explicará el funcionamiento del perceptrón multicapa.

3.3 PERCEPTRÓN MULTICAPA

Es una de las redes neuronales más utilizadas, por su capacidad de aprendizaje, generalización y tolerancia a fallos. Una red neuronal puede ser descrita completamente mediante los parámetros mostrados en la tabla 21.

3.3.1 Funcionamiento. El algoritmo de aprendizaje de la red es supervisado y estático, es decir la red aprende con datos de entrada/salida y solo durante la fase de entrenamiento. El entrenamiento se inicia con la presentación de un dato en la capa de entrada, el cual es propagado a través de toda la red hasta llegar a la capa de salida, donde se genera una salida que es comparada con la salida deseada. La determinación del error cometido por la red, se calcula mediante la siguiente expresión:

$$e = S_{(generada)} - S_{(deseada)} \quad (8)$$

Tabla 9. Principales parámetros de la Red

PARÁMETRO	VALOR
Número de capas de neuronas	Mínimo 3, depende de cada situación.
Número de neuronas por capa	Mínimo 1, también depende de la situación
Tipo de conexiones	Hacia adelante o feedforward
Grado de conectividad	Completa, entre capas adyacentes
Mecanismo de aprendizaje	Supervisado
Asociación entre la información de E/S	Heteroasociativa
Representación de la información de E/S	Continua

Cuando el error cometido por la red es superior al valor mínimo establecido, entonces se calcula el error cometido por las neuronas en la capa de salida. Los errores son transmitidos hacia las capas internas, donde cada neurona recibe un porcentaje del error total. Los pesos de las neuronas son modificados según la contribución de cada neurona al error total, mediante la expresión:

$$\Delta W_{ji} = \alpha y_i (d_i - y_i) \quad (9)$$

Donde α es la tasa de aprendizaje, que permite regular la magnitud del cambio en los diferentes pesos. Una vez modificados los pesos el proceso se repite con todos los datos, hasta alcanzar el nivel mínimo de error.

El proceso de entrenamiento mediante el método de retropropagación, también conocido como regla delta generalizada o método del gradiente descendiente, es asociado con la búsqueda de un mínimo que satisface el criterio de error, sobre una superficie de energía multidimensional. En la superficie de energía las variables independientes son el conjunto de pesos y la dependiente es el error cometido por la red. Durante la búsqueda del conjunto de pesos que satisfacen

el criterio de error, sobre la superficie de energía, se debe avanzar mediante pasos pequeños (α , pequeño), para evitar pasar por encima de un mínimo que puede satisfacer el criterio de error. El parámetro alfa (α), no garantiza que la red no pasará por encima de un mínimo y que oscile cerca del mismo. Para evitar la anterior situación, a la ecuación 17 se le adiciona un término llamado momento (β). La nueva expresión para modificar los pesos es:

$$W_{ji}(t+1) = W_{ji}(t) + \alpha(d_i - y_j) + \beta(w_{ji}(t) - w_{ji}(t-1)) \quad (10)$$

La función de Beta (β), es mantener el cambio de los pesos en la misma dirección (positiva), mediante la adición de una fracción del cambio anterior. La convergencia de la red depende de los valores de las constantes alfa y beta, del valor inicial de los pesos y del número de neuronas ocultas. El asentamiento de la red en un mínimo global o local termina el aprendizaje. El problema se presenta cuando el conjunto de pesos asociado con ese mínimo local, no permite una solución aceptable desde el punto de vista del error, siendo necesario repetir el entrenamiento de la red, cambiando las condiciones iniciales.

El proceso de entrenamiento del perceptrón multicapa es lento, por lo que se recomienda iniciar el proceso con un valor pequeño de alfa, que garantiza que no se pasará por encima del mínimo, y en la medida que disminuye el error aumentar el valor de alfa, para celebrar la convergencia de la red.

3.4 LÓGICA DIFUSA

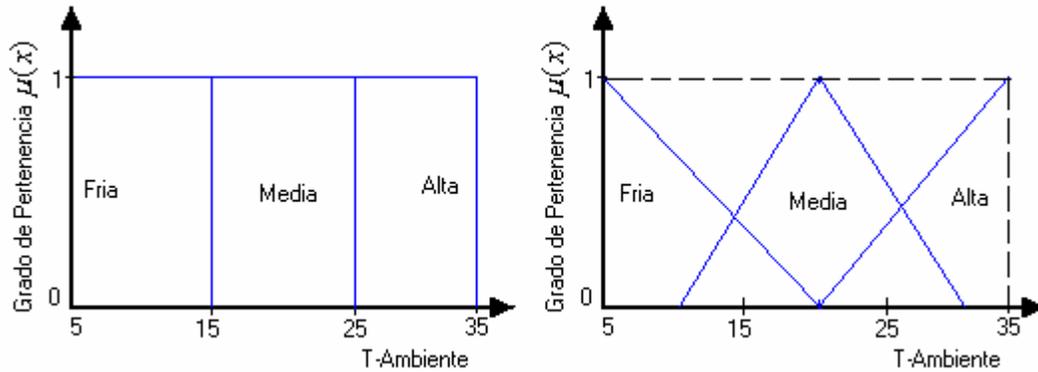
La Lógica Difusa o **fuzzy logic**, es la rama de las matemáticas que se encarga del procesamiento de información ambigua. Entiéndase por información ambigua expresiones como: LA VELOCIDAD ES ALTA. Los modelos difusos se basan sobre hechos ciertos pero imprecisos.

La forma más elemental de pensamiento y su transmisión, se hace mediante palabras, que conforman expresiones difusas. La lógica difusa aparece como respuesta a las dificultades presentadas por la tradicional lógica binaria, donde no existen estados intermedios. Mediante lógica difusa se establece el grado de pertenencia de un elemento a uno o varios conjuntos con los que se relaciona, y su valor se encuentra dentro del rango continuo $[0,1]$, donde 0 indica ausencia de pertenencia y el 1 pertenencia total (ver figura 13).

3.4.1 Características. Dentro de las características mas representativas de la lógica difusa figuran:

- Fácil incorporación del conocimiento. Uno de los principales problemas que se presentan en el modelado de sistemas relativamente complejos es la determinación de la ecuación que lo gobierna. La lógica difusa permite describir el sistema mediante un conjunto de reglas lingüísticas, omitiendo el uso de los constructores matemáticos particulares. Las reglas que describen el sistema provienen del conocimiento y experiencia de un experto en el área, por lo tanto los sistemas difusos hacen parte de los llamados sistema basados en el conocimiento.
- Fácil modificación del modelo. En muchas ocasiones es necesario modificar o ajustar parámetros en el modelo creado. En los modelos matemáticos convencionales muy seguramente es necesario replantear parcial o totalmente el modelo, pero en los modelos difusos, por estar constituidos por un conjunto de reglas lingüísticas, puede ser suficiente modificar, eliminar o adicionar reglas al sistema.

Figura 13 Conjuntos tradicionales y difusos, respectivamente



- Explicación de los resultados. La determinación de las reglas que participaron en el proceso de inferencia permite conocer como se llegó al resultado final. Ello es posible mediante el seguimiento de las reglas involucradas en el proceso de inferencia. Las reglas por ser de tipo lingüístico, son de fácil interpretación.

3.4.2 Aplicaciones. En la Tabla 22 se muestran algunas de las aplicaciones que ha tenido la lógica difusa en diferentes áreas del conocimiento.

Tabla 50. Algunas aplicaciones de la lógica difusa.

AREA	APLICACIONES
Informática	Computadores, desarrollo de software
Transporte	Sistemas de transmisión y frenado de autos
Industria	Robots, reconocimiento de patrones
Economía	Análisis de mercados y riesgos
Simulación	Modelado de sistemas no lineales
Microelectrónica	Fabricación de chips

3.4.3 Elementos de un sistema de inferencia difuso. Dentro de los principales elementos que caracterizan un sistema de inferencia difuso figuran:

- **Conjuntos Difusos:** En lógica difusa los conjuntos también son una colección de elementos con una serie de características similares, pero cada elemento puede estar relacionado con varios conjuntos simultáneamente y tener un grado de pertenencia diferente a cada uno de ellos, en contraposición a la lógica binaria donde los conjuntos son tratados como un todo. En los conjuntos difusos al igual que en los convencionales, se pueden realizar operaciones como: unión, intersección, complemento, etc.
- **Variable difusa:** En el modelado de un sistema, a cada variable se le asigna un nombre de variable difusa, para ser posteriormente descrita en función de su espacio difuso.
- **Variables lingüísticas:** Se denomina variables lingüísticas a cada una de las categorías en que se divide la variable difusa, por ejemplo si consideramos la variable lingüística velocidad, sus términos lingüísticos podrían ser baja, media y alta, que describen la variable difusa en todo su espacio (ver figura 14).
- **Funciones de Pertenencia:** En el proceso de inferencia difuso, es necesario evaluar el grado de pertenencia de los elementos dentro de las diferentes variables lingüísticas. Las funciones que son utilizadas para determinar el grado de pertenencia se denominan funciones de pertenencia. Ellas como lo muestra la figura 15, pueden ser de diferentes tipos: triangular, trapezoidal, gaussiana, entre otras. La elección del tipo de función a utilizar, depende del tipo de variación que presenten los elementos a evaluar.

- Universo del discurso. Es el conjunto de valores admisibles para una variable difusa.

Figura 14. Elementos de una variable difusa.

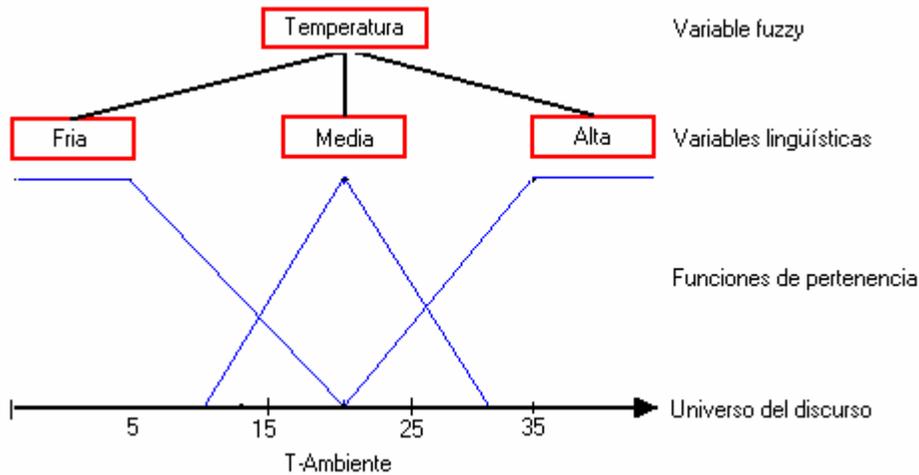
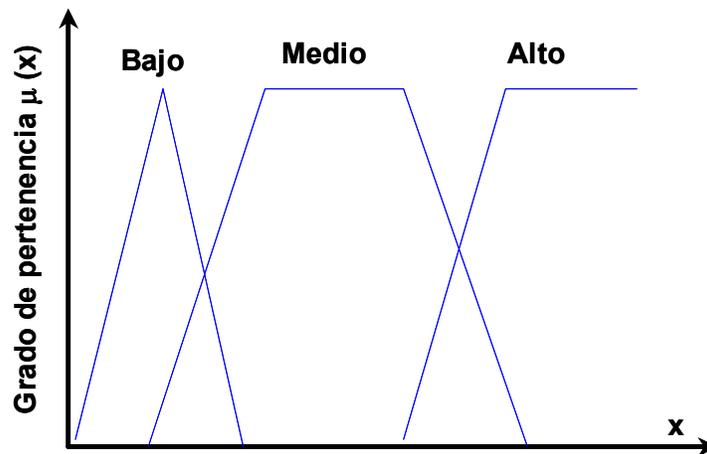


Figura 15. Algunas formas de funciones de pertenencia



- Reglas lingüísticas. Son una serie de reglas que establecen relaciones entre las variables de entrada y salida en el modelo. Las reglas lingüísticas se encuentran constituidas por dos partes; la primera es el antecedente, el cual relaciona el valor de entrada con la(s) variables lingüística(s) que contenga(n)

dicho valor. La segunda parte es el consecuente, y realiza la misma función que el antecedente, pero sobre la(s) variable de salida(s). Las reglas lingüísticas tienen la siguiente forma:

Si (C2H2 rate es Alto) Entonces (FRT es Bajo)

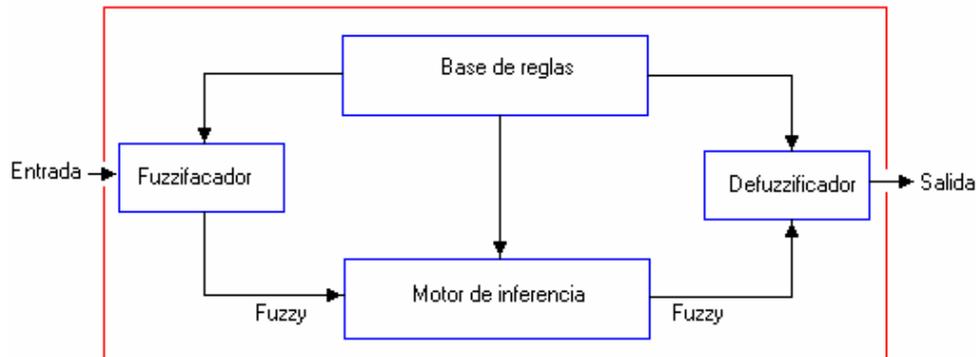
Donde alto y bajo, son conjuntos difusos que pertenecen a las variables de entrada y salida del sistema (C2H2 rate y FRT) respectivamente.

En los sistemas difusos que presentan múltiples entradas y/o salidas, se utilizan operadores lógicos (**AND, OR Y NOT**), para relacionar las diferentes variables en el antecedente y/o el consecuente de la regla, según sea el caso. Por ejemplo;

Si (C2H2 rate es Bajo) y (PF% es Alto) Entonces (FRT es Medio)

3.4.4 Proceso de inferencia difuso. En el proceso de inferencia, como se observa en la figura 16), se pueden distinguir 3 etapas a saber:

Figura 16. Sistema de inferencia difuso.

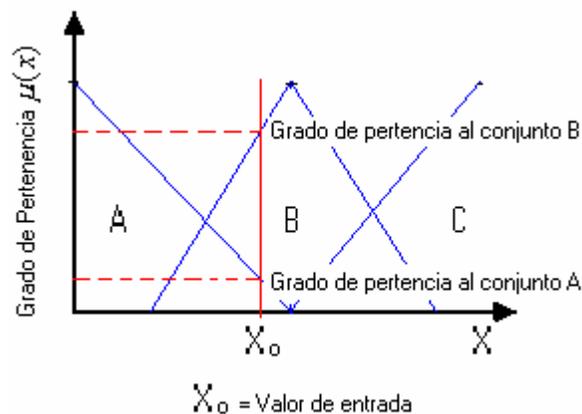


- Fuzzificación de las entradas. Se entiende por fuzzificación el proceso mediante el cual se establece el grado de pertenencia de un valor de entrada

al o los conjuntos difusos con los que se encuentra relacionado (ver figura 17), mediante funciones de pertenencia. En otras palabras en transformar un valor escalar, en difuso. El grado de pertenencia de un elemento al conjunto difuso, que lo contiene total o parcialmente, se denota por $\mu(x)$, que es un valor contenido en el rango [0 1].

- Evaluación de las reglas de control. En el proceso de construcción del modelo, el experto debe transmitir su conocimiento y experiencia en forma de reglas lingüísticas. El proceso de evaluación consiste en determinar que reglas se activarán, a partir de la información obtenida en la etapa anterior. Además a cada regla se le asocia un parámetro llamado peso, que equivale al grado de pertenencia del elemento con el conjunto difuso, indicado por el antecedente de la regla que se evalúa. El peso permite establecer el grado de pertenencia de la salida al conjunto que se encuentra en el consecuente de la regla.

Figura 17. Proceso de fuzzificación de las entradas.



Las reglas de control se encuentran almacenadas en lo que se denomina la base reglas. Una base con 3 reglas de control puede ser:

Regla 1: Si (**C2H2 rate es Alto**) Entonces (**FRT es Bajo**)

Regla 2: Si (**C2H2 rate es Medio**) Entonces (**FRT es Medio Alto**)

Regla 3: Si (**C2H2 rate es Bajo**) Entonces (**FRT es Alto**)

- Defuzzificación de las Salidas. La defuzzificación de las salidas es el proceso inverso a la fuzzificación, consiste en determinar un valor numérico a partir de los conjuntos difusos activos y ponderados, procedentes de la evaluación de las reglas de control.

La defuzzificación se puede llevar a cabo mediante diferentes métodos. Uno de los más comunes es el método del centro de gravedad el cual consiste básicamente en construir un nuevo conjunto de salida mediante la unión de los conjuntos activos y ponderados (procedentes de la evaluación de las reglas de control), y determinar el centro de gravedad del nuevo conjunto (ver figura 18). Para la construcción del nuevo conjunto se puede utilizar el producto lógico difuso, que se interpreta como la unión de los conjuntos activos y ponderados, acotados superiormente por el valor de los pesos. La expresión que calcula el grado de pertenencia de la salida es:

$$\mu_s(y) = \min(\text{peso} - \text{regla } R_1, \mu_{s1}(y)) + \min(\text{peso} - \text{regla } R_2, \mu_{s2}(y)) \quad (11)$$

Una vez construida la figura, se procede a calcular el centro de gravedad mediante la siguiente expresión:

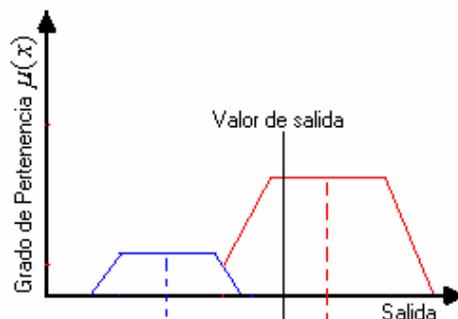
$$\bar{y} = \frac{\int y\mu(y)dy}{\int \mu(y)dy} \quad (12)$$

El sistema de inferencia descrito se conoce como de Mandami; adicionalmente existe otro conocido como sistema de inferencia de Sugeno, y se diferencia del anterior, porque en el consecuente de las reglas de control, los conjuntos difusos son reemplazados por valores constantes o por una ecuación. Los dos tipos de reglas lingüísticas son:

Si (PF% es **Alto**) Entonces (FRT es k_i)
Si (PF% es **Alto**) Entonces (FRT es $mx + b$)

Donde k_i , es una constante que representa la salida del sistema para un valor de entrada. La ecuación de $mx + b$, representa la ecuación de la variable de entrada.

Figura 18. Método del centro de gravedad



3.4.5 Desventajas de la lógica difusa. Como cualquier método la lógica difusa presenta algunas desventajas que deben tenerse en cuenta para su uso:

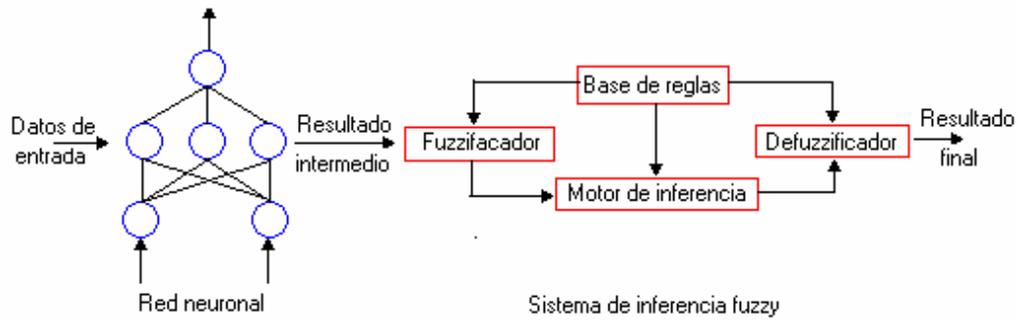
- Incapacidad de generar de manera autónoma su base de reglas.
- Incapacidad de refinar automáticamente sus funciones de pertenencia.
- Dificultad de establecer reglas que respondan a todas las posibles configuraciones de las variables de entrada.
- Dificultad en obtener reglas de expertos.

3.5 SISTEMAS QUE COMBINAN LAS REDES NEURONALES Y LÓGICA DIFUSA

Existen diferentes formas de combinar redes neuronales y sistemas difusos, pero solo algunas combinaciones han permitido superar desventajas y aprovechar ventajas de cada técnica. La flexibilidad que presentan las redes neuronales y la lógica difusa, al momento de ser combinadas ha permitido la generación de múltiples modelos, cada uno de ellos con diferente grado de integración entre técnicas. Algunos tipos de modelos que combinan redes neuronales y sistemas difusos se explican a continuación.

3.5.1 Modelos concurrentes. Es la forma más elemental y débil de combinar las redes neuronales y la lógica difusa, en los modelos concurrentes el sistema se encuentra constituido mínimo por una red neuronal y un sistema difuso, donde la red neuronal puede actuar como preprocesador o postprocesador del sistema difuso (ver figura 19). En este caso el aprendizaje solo modifica parámetros de la red neuronal, siendo tarea del experto la generación de las reglas de control y el refinamiento de las funciones de pertenencia.

Figura 19. Red neuronal, como preprocesador.



3.5.2 Modelos cooperativos. Los modelos cooperativos presentan un mayor grado de integración entre las técnicas. La arquitectura en los modelos cooperativos es la de un sistema difuso, donde las redes neuronales son utilizadas en el aprendizaje de parámetros del modelo, consecuentemente el modelo tendrá una mayor adaptabilidad. Los parámetros que pueden ser aprendidos por las redes neuronales artificiales son: funciones de pertenencia, reglas lingüísticas, factores de peso entre reglas, e incluso refinación de funciones de pertenencia.

La figura 19, muestra la utilización de una red neuronal derivando conjuntos difusos. La figura 20, describe como una red neuronal aprende las reglas de control de un sistema. Asimismo, la figura 21 muestra la utilización de una red neuronal para determinar factores de peso para posteriormente ser usados en el proceso de inferencia.

Figura 20. Red neuronal que deriva conjuntos difusos.

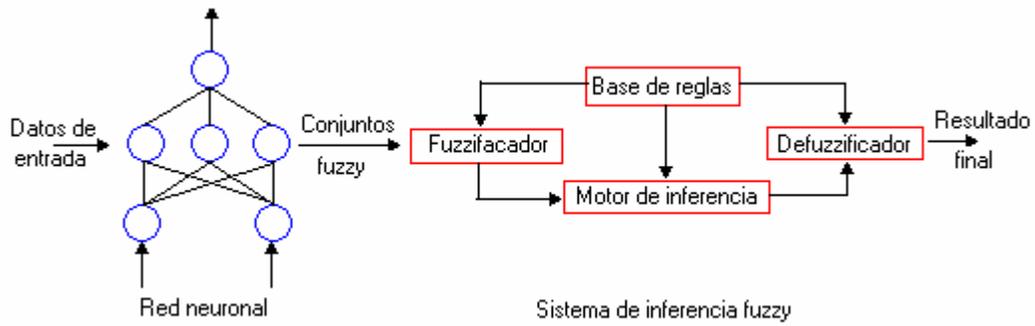


Figura 21. Red neuronal derivando reglas difusas.

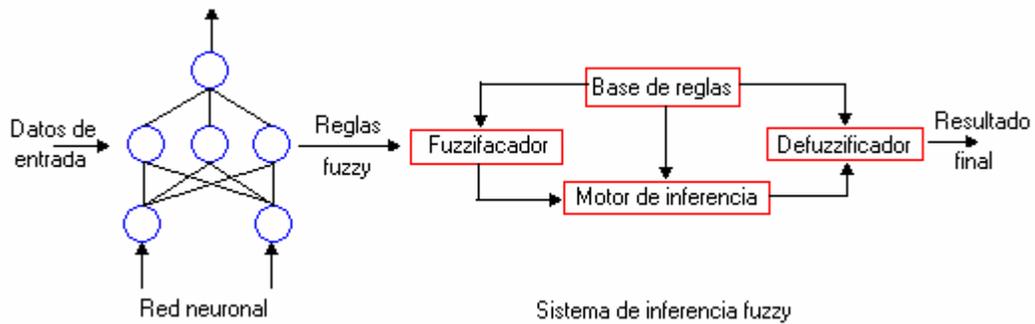
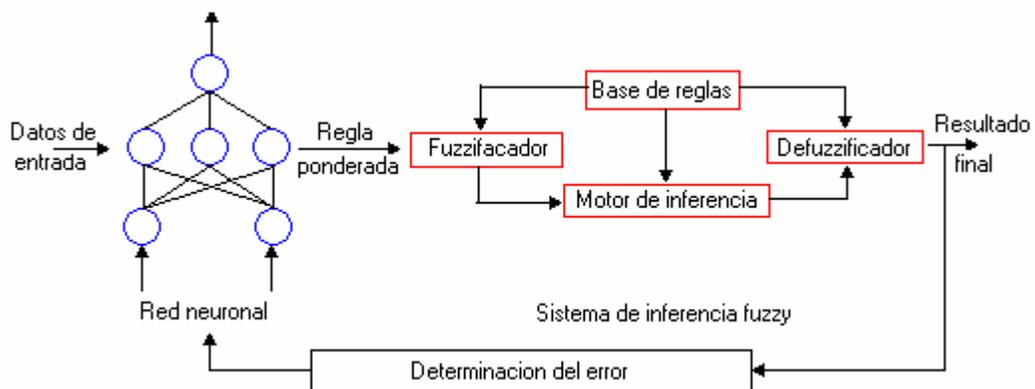


Figura 22. Red neuronal aprendiendo factores de peso.



3.5.3 Modelos híbridos Neurodifusos. La idea fundamental en estos modelos es la creación de una estructura de procesamiento paralelo, con capacidad de

aprendizaje y generalización; además el conocimiento adquirido durante el aprendizaje, debe ser de fácil de interpretar. La descripción anterior es el planteamiento de una red neuronal especial, donde los pesos son conjuntos difusos y las neuronas de pueden ser interpretadas como variables de entrada, reglas lingüísticas y variables de salida.

Para el entrenamiento de los modelos híbridos se utilizan algoritmos propios de las redes neuronales o variaciones. En una red neurodifusas el entrenamiento también consiste en la modificación sistemática de los pesos. El entrenamiento de un sistema como el descrito puede ser enfocado desde dos puntos de vista: primero, desde la óptica de las redes neuronales, el entrenamiento es una evolución de la arquitectura, debido a la generación y eliminación de pesos. Segundo, el entrenamiento en términos de los sistemas difusos consiste en la refinación, generación y eliminación de conjuntos difusos. El ANFIS pertenece a esta categoría.

3.6 ANFIS

El acrónimo ANFIS, derivado de su nombre, **Adaptive Neuro Fuzzy Inference System**, es un híbrido capaz de aprender a realizar una tarea, de extraer y refinar su base de reglas, y sus funciones de pertenencia. El ANFIS conserva la estructura de una red neuronal, pero el procesamiento de las señales es difuso, lo que le permite una gran capacidad de adaptación y generalización.

3.6.1 Características. Dentro de las características más relevantes del ANFIS figuran:

- Aprendizaje adaptativo. Característica heredada de las redes neuronales, que le permite aprender a realizar una tarea, a partir de datos representativos. La

convergencia del ANFIS, en el entrenamiento, es mucho más rápida que en las redes neuronales, debido a la incorporación de conocimiento antes de iniciar entrenamiento. El entrenamiento del ANFIS es supervisado, por lo que se requiere que los ejemplos a utilizar en el entrenamiento contengan información de entrada y salida, del sistema a emular.

- Extracción y refinación de reglas. La extracción y refinación de las reglas lingüísticas, es la principal consecuencia de la hibridación, ya que el conocimiento adquirido, puede ser interpretado en forma de lenguaje natural. Las reglas lingüísticas del sistema conservan la forma del sistema de Sugeno.
- Refinamiento de las funciones de pertenencia. El ajuste de las curvas de las funciones de pertenencia, a los datos de entrenamiento, facilita la convergencia de la red. A diferencia de las reglas lingüísticas que son extraídas de los datos, el número y tipo de funciones de pertenencia son establecidos por el experto. La selección del número y tipo de funciones de pertenencia es crucial para alcanzar resultados satisfactorios.
- Interpretación de resultados. Característica heredada de la lógica difusa, consistente en determinar los distintos parámetros involucrados en el proceso de inferencia, lo cual permite explicar el origen de un resultado. La interpretación de resultados se facilita debido a que el consecuente de las reglas lingüísticas es un valor constante.

El ANFIS y las redes neuronales pueden ser descritos mediante los mismos parámetros (ver tabla 23).

Tabla 11. Principales parámetros del ANFIS.

PARÁMETRO	VALOR
Número de capas de neuronas	5, con 3 capas ocultas
Número de neuronas por capa	Mínimo una, en las cuatro primera capas y una única neurona en la capa de salida.
Tipo de conexiones	Hacia adelante o feedforward.
Grado de conectividad	Completa, entre capas adyacentes.
Mecanismo de aprendizaje	Supervisado. Retropropagación simple o combinado con el método de los mínimos cuadrados.
Asociación entre la información de E/S	Heteroasociativa
Representación de la información de E/S	Análoga

3.6.2 Capas de neuronas en el ANFIS. En el ANFIS el número de capas siempre es de cinco, donde cada capa cumple una función específica en el proceso de inferencia neurodifuso. A continuación se describen el tipo a que pertenecen y la función que desempeña cada una de las capas.

- Primera capa o capa de entradas, en ella se presentan los datos al sistema. Su función es determinar si los valores introducidos se encuentran en el intervalo admisible y entregarlos a la capa siguiente. Todos los pesos de las conexiones con la capa dos, tienen un valor de uno.
- Segunda capa o capa de fuzzificación. En ella se determina el grado de pertenencia de las entradas, a los diferentes conjuntos difusos, que componen el universo del discurso para cada variable. Los pesos de las conexiones con las capas tres, son modificados durante el entrenamiento, almacenando parte del conocimiento del híbrido.
- Tercera capa. En ella se encuentra el antecedente de cada regla lingüística. Cada neurona desarrolla el antecedente de una regla lingüística. Las reglas

no pueden ser alteradas, porque cambiaría el conocimiento del sistema; aquí los parámetros de aprendizaje son los pesos de las conexiones con la capa siguiente. Las neuronas en esta capa no realizan el proceso de evaluación de cada regla, solo determinan el grado de pertenencia del antecedente a la regla. La evaluación total de la regla se completa con la cuarta capa porque en ella se encuentra el consecuente de la regla.

- Cuarta capa o capa de inferencia. Su función es tomar los valores de la capa anterior, para completar la evaluación de la regla. Los pesos de las conexiones con la capa anterior también son ajustados durante el entrenamiento. Al igual que en la capa tres, no se debe alterar los valores internos de cada neurona, porque aquí se encuentra la información de los diferentes conjuntos difusos que conforman la variable de salida.
- Quinta capa o capa de defuzzificación. Su función es convertir la información difusa procedente de la capa anterior en un valor numérico y brindar un resultado. El método de defuzzificación utilizado es el método del centro de gravedad. La figura 22 muestra la estructura interna de una estructura ANFIS con dos entradas.

3.6.3 Entrenamiento y funcionamiento. Se debe disponer de un conocimiento previo de la tarea y un conjunto de datos que la describan. El número y tipo de funciones de pertenencia, se deben establecer previamente al entrenamiento. Es aquí donde el experto comienza a incorporar conocimiento al sistema. El entrenamiento consiste en la presentación iterada de los datos, y termina una vez alcanzado un error mínimo o un número de iteraciones. Durante el entrenamiento la información es propagada por toda la red desde la capa de entrada hasta la capa de salida.

Para generar la base de reglas, disminuir el nivel de error a un valor mínimo y refinar las funciones de pertenencia durante el entrenamiento. En este trabajo se utilizó una combinación del clásico algoritmo retropropagación y el método de los mínimos cuadrados. El método de los mínimos cuadrados, se encarga del refinamiento de las reglas de control y de las funciones de pertenencia, durante la propagación de las señales desde la capa de entrada hacia la capa de salida en la red. La modificación de los pesos es realizada mediante retropropagación, de igual forma que en redes neuronales. Una vez terminado el entrenamiento, también se debe evaluar el comportamiento de la red mediante una validación. El resultado final es una superficie n-dimensional (ver figura 23), donde las entradas del sistema son las variables independientes y la salida es la variable dependiente. Cada punto de la superficie representa un estado del sistema, y se encuentra dividida en tantas regiones como reglas de control tenga el sistema.

Figura 23. ANFIS con 2 entradas.

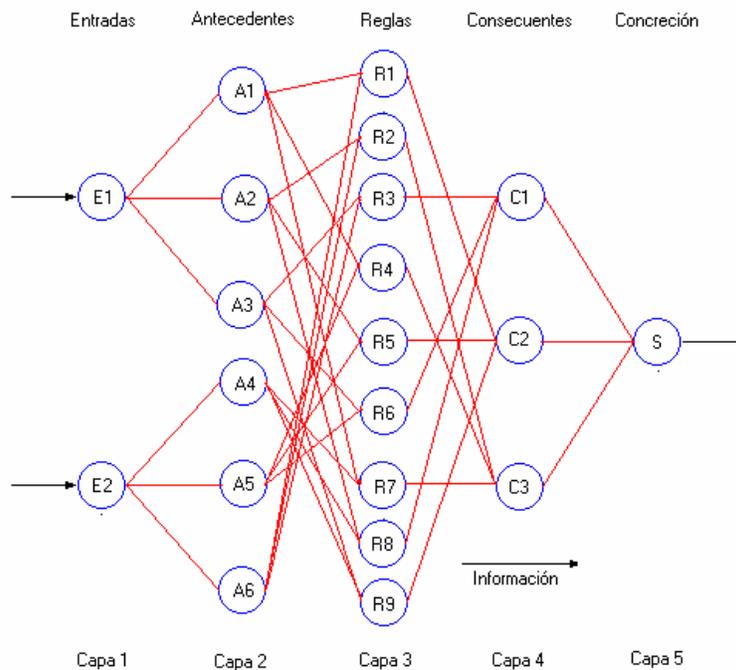
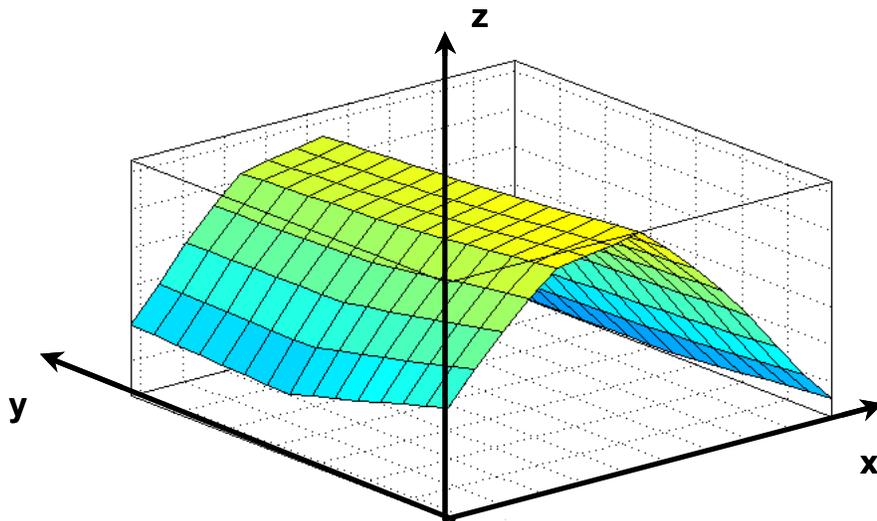


Figura 24. Superficie de control generada por el ANFIS



3.7 INTERPOLACIÓN DE DATOS

La interpolación no es término exclusivamente matemático, sino que se usa en otros ámbitos de la vida, por ejemplo en fotografía y más generalmente en tratamiento de imágenes y señales. En el proceso de interpolación se trata de obtener un polinomio que obtenga los mismos valores correspondientes a una serie de datos previamente conocida. A dicho polinomio se denomina polinomio interpolador y, si mediante él se calcula el valor en otro punto cualquiera, éste valor es un valor de interpolación. Está claro que en el proceso de interpolación se comete un error de aproximación. Este error, o bien se estima estadísticamente o bien se acota para determinar que no puede ser mayor que un determinado valor límite.

3.8 IMPLEMENTACIÓN DEL ESQUEMA DE EVALUACIÓN BAJO CADA UNA DE LAS TÉCNICAS PROPUESTAS

Una vez revisada la fundamentación teórica alrededor de cada una de las técnicas planteadas para la solución del problema, se pasó a su aplicación y posterior análisis comparativo de los resultados obtenidos con cada una. El plan de trabajo contempló el desarrollo de los siguientes pasos:

- Preparación de información y elaboración de casos para entrenamiento, verificación y chequeo.
- Análisis de Componentes Principales (PCA) al grupo de datos obtenidos de los casos seleccionados para asegurar la no correlación de los componentes finales y tratar de reducir la dimensionalidad del problema.
- Aplicación de las técnicas elegidas y obtención de los vectores resultado para los casos seleccionados.
- Comparación de los resultados obtenidos con la aplicación de cada una de las técnicas.

3.8.1 Preparación de información y elaboración de casos para entrenamiento, verificación y chequeo. Con base en la información recopilada y evaluada sobre trabajos anteriores y teniendo en cuenta la disposición de la caja de herramientas de lógica difusa del programa MATLAB se decidió realizar la implementación bajo lógica neurodifusa usando la aplicación ANFIS del mismo programa. Dada la independencia existente entre los dos aspectos generales de evaluación (Factor de Riesgo Total y Señal de Envejecimiento Total) y teniendo en cuenta la mayor complejidad y cantidad de variables que rodea al primero de ellos, se decidió realizar la implementación con el subesquema de evaluación del Factor de Riesgo Total únicamente.

En la preparación de la información para el entrenamiento y verificación de desempeño del sistema inicialmente se contempló la posibilidad de generar casos aleatorios para mejorar el cubrimiento del universo de discurso de las variables parciales y de la variable resultado. Esta alternativa también ha sido contemplada por otros investigadores [18] como una forma de mejorar el entrenamiento y desempeño de sistemas de este tipo. Lo anterior se explica por la poca cantidad de casos de falla o anormalidad de condición de equipos que generalmente se encuentran en proporción a la totalidad de la población de datos evaluada. Para este caso, la información histórica de los últimos 10 años de pruebas y análisis realizados a los equipos de ISA suministró mas de 800 casos cuya evaluación final cubría la totalidad del rango de salida contemplado para la variable Factor de Riesgo Total (1 a 5) donde 1 es considerado crítico y 5 se considera excelente. La Tabla No 24 muestra la distribución de los casos reales identificados de acuerdo con los rangos de los valores de la variable de salida FRT.

Tabla 12. Distribución de la población total de casos reales identificados.

Rango de salida	Cantidad de casos	% del total
1 - 2	259	29,98%
2 - 3	323	37,38%
3 - 4	117	13,54%
4 - 5	165	19,10%

Una de las mayores dificultades encontradas en la determinación de los casos reales fue la diferente periodicidad existente entre algunas series de datos provenientes de ejecución de pruebas y análisis. Como ejemplo, la periodicidad de ejecución de los análisis de gases disueltos en aceite y la medición de factor

de potencia de aislamientos es para el primer caso de 1 año y para el segundo de 6 años. Dicha periodicidad de ejecución de cada análisis o prueba está determinada por el plan de mantenimiento elaborado el cual se basa en una estrategia que incluye la probabilidad de ocurrencia normal del modo de falla, la experiencia del personal ejecutor y el análisis de efectividad de cada tarea en la detección de los diferentes modos de falla. Para el caso que nos ocupa, en ISA la periodicidad de ejecución de algunas de estas tareas y actividades de mantenimiento han cambiado en los últimos años con la implementación de la estrategia de Mantenimiento Centrado en Confiabilidad o MCC la cual se establece a partir de una serie de factores que caracterizan la funcionalidad del equipo más que al equipo mismo. Es así como equipos de características similares en entornos operativos y ciclos de exigencia diferentes pueden tener asignados diferentes periodicidades de ejecución para las mismas tareas de mantenimiento.

Otra dificultad encontrada a la hora de seleccionar los casos reales fue el cambio tecnológico que experimentaron algunas de las metodologías de medición y pruebas en campo y laboratorio lo cual afectó la tendencia histórica y variabilidad de algunos resultados. Como ejemplo, en 1997 se cambió el cromatógrafo de gases que permite realizar el análisis DGA (Análisis de Gases Disueltos en Aceite) a partir del cual se obtienen los valores de concentraciones e incrementos de gases usados como variables en la estructura de evaluación de condición de transformadores y reactores. El nuevo cromatógrafo tiene mayor resolución y precisión que al anterior y la trazabilidad de sus resultados es mucho mejor lo que hace difícil establecer comparaciones entre series de resultados obtenidos antes y después de la implementación de esta nueva tecnología. Otro aspecto que experimentó cambios tecnológicos alrededor de 1996 fue la medición de factor de potencia de aislamientos al incorporar nuevos equipos que incluían técnicas de filtrado digital para reducir o eliminar el efecto en los resultados de la medición de la interferencia eléctrica la cual se encuentra presente en subestaciones de alta

tensión durante la ejecución de estas mediciones. Como resultado de todo lo anterior, fue necesario limitar el grupo de datos que conformarían los diferentes casos a los obtenidos durante los últimos 8 años.

Para solucionar los inconvenientes descritos anteriormente y poder obtener una mayor cantidad de casos reales, se decidió interpolar linealmente entre aquellas variables que tenían una mayor periodicidad de ejecución (caso medición de factor de potencia de aislamientos y análisis fisicoquímico de aceites) previa verificación de la consistencia en la tendencia de crecimiento de la variable. Lo anterior permitió obtener 864 casos reales con los cuales se diseñó y verificó el desempeño de la estructura de evaluación de condición. El formato de registro de los casos reales incluyó la calificación de condición asignada por un grupo de expertos en el área de análisis de condición de equipos. Del total de casos reales se conformaron aleatoriamente grupos de datos de diferente tamaño para la construcción, validación y prueba del esquema de evaluación desarrollado bajo las dos técnicas descritas inicialmente.

3.8.2 Análisis de Componentes Principales (PCA). El Análisis de Componentes Principales (ACP) es una técnica estadística de síntesis de la información, o reducción de la dimensión (número de variables). Es decir, ante un banco de datos con muchas variables, el objetivo será reducirlas a un menor número perdiendo la menor cantidad de información posible. Los nuevos componentes principales o factores serán una combinación lineal de las variables originales, y además serán independientes entre sí. Un aspecto clave en ACP es la interpretación de los factores, ya que ésta no viene dada a priori, sino que será deducida tras observar la relación de los factores con las variables iniciales (habrá, pues, que estudiar tanto el signo como la magnitud de las correlaciones). Esto no siempre es fácil, y será de vital importancia el conocimiento que el experto tenga sobre la materia de investigación. El ACP es un método muy eficaz

para el análisis de datos cuantitativos (continuos o discretos) que se presentan bajo la forma de cuadros de M observaciones / N variables y permite:

- Visualizar y analizar rápidamente las correlaciones entre las N variables.
- Visualizar y analizar las M observaciones inicialmente descritas por N variables en un gráfico de dos o tres dimensiones, construido de tal forma que la dispersión entre los datos se preserve tanto como sea posible.
- Construir un conjunto de P factores no correlacionadas ($P \leq N$) que pueden luego ser reutilizados por otros métodos (la regresión por ejemplo).

El Análisis de Componentes Principales es a menudo utilizado ante una regresión ya que permite evitar el uso de variables redundantes, o ante una clasificación ya que permite identificar la estructura de la población y eventualmente determinar el número de grupos a construir.

Con ayuda de la función “princomp” de la caja de herramientas de Optimización de MATLAB, se hizo un ACP al grupo de datos obtenido de los casos reales conformados. Previo a este procedimiento y atendiendo recomendaciones obtenidas de la experiencia en proyectos similares que usaron sistemas híbridos neurodifusos, se decidió realizar la normalización previa de los datos entre un rango de 0.3 a 0.7. Lo anterior facilita entre otros la comparación y cálculo del error existente entre el grupo de resultados obtenidos y el vector objetivo al eliminar la posibilidad que existan divisiones entre cero al calcular el error porcentual de la diferencia entre los resultados y el vector objetivo entre este último.

Los resultados obtenidos con la aplicación del ACP pueden visualizarse en forma de gráficos de correlación entre los diferentes componentes como se muestra en

la figura No 25. Una forma más sencilla de verificar la efectividad del análisis en la reducción de la dimensionalidad del problema son los valores de porcentajes de la varianza de la población inicial de datos que explica cada uno de los componentes principales identificados. La Tabla 25 así como la figura 26 comparan estos porcentajes de explicación y permiten seleccionar objetivamente el número de componentes principales a usar en la definición de la estructura del esquema de evaluación. De los resultados obtenidos se observa que los dos primeros componentes principales identificados explican alrededor del 72% de la varianza total de la población inicial de datos en tanto que los tres principales explican alrededor del 85% de la misma.

Tabla 13. Valor de varianza porcentual para cada componente principal identificado.

Orden del componente	Varianza porcentual (%)
Primero	49.22
Segundo	22.37
Tercero	13.50
Cuarto	7.36
Quinto	4.68
Sexto	2.84

Figura 25. Gráfico de correlación entre el primer y segundo componente principal identificados.

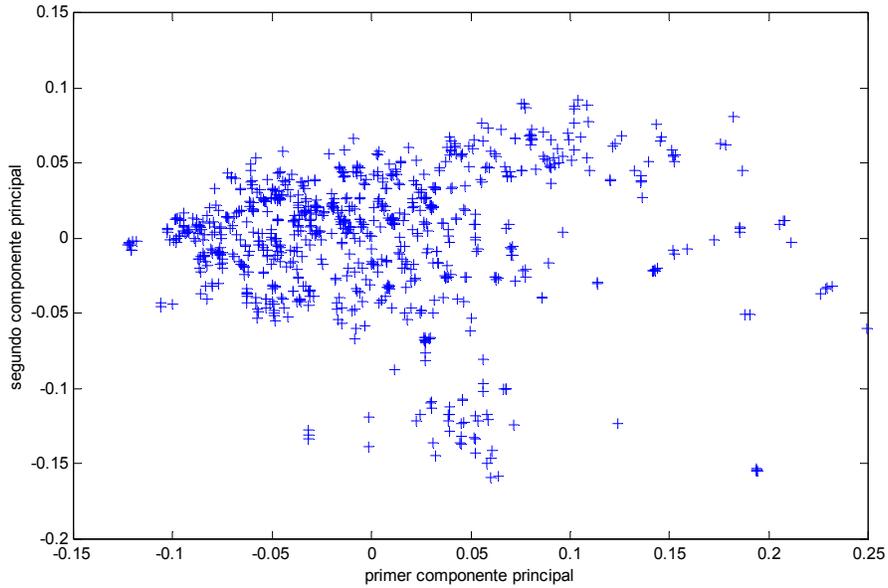
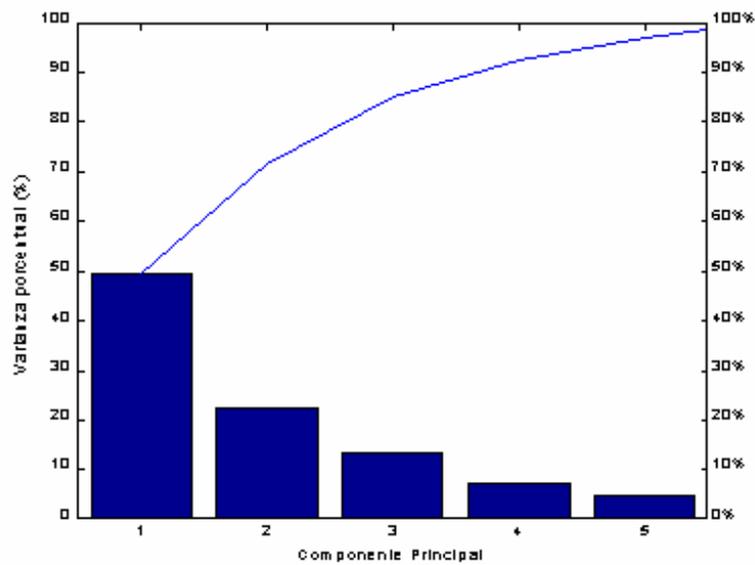


Figura 26. Resultados de la aplicación del análisis de componentes principales PCA al archivo de datos seleccionados.



3.8.3 Implementación del esquema de evaluación bajo la técnica de interpolación multidimensional. Una vez obtenidos y normalizados la totalidad de los casos reales disponibles e identificados sus componentes principales como se explicó en la sección anterior, se procedió desarrollar la estructura de evaluación usando la técnica de interpolación multidimensional. Para verificar el desempeño de la técnica se seleccionó aleatoriamente un grupo de 400 casos del grupo inicial que conformaron el grupo de entrenamiento. Con base en esta información, y usando dos grupos adicionales de casos previamente evaluados y también seleccionados aleatoriamente (“entrenamiento” y “verificación”) se verificó el desempeño evaluando el error existente entre la calificación obtenida por la técnica de interpolación con la asignada previamente por un grupo de expertos en el área de diagnóstico. La rutina de programación implementada contempló los siguientes pasos:

- Selección aleatoria de datos para la conformación de los grupos de entrenamiento, validación y chequeo.
- Interpolación multidimensional tomando desde uno hasta cinco componentes principales usando la función “griddatan” de la caja de herramientas de optimización de MATLAB y partiendo de los 400 casos con calificación conocida que conformaban el grupo de “entrenamiento”. En este paso se usaron dos métodos de cálculo disponibles en la función mencionada: “cercano” o “**neirest**” y “lineal”. Lo anterior conformó un grupo final de 20 resultados asociados a los dos tipos de método de cálculo (“lineal” y “cercano”), a los dos grupos de casos usados para verificar el desempeño (“entrenamiento” y “verificación”) y a las 5 dimensiones mencionadas asociadas al número de componentes principales considerados en cada prueba.

- Identificación de casos en los grupos de verificación y prueba donde la interpolación, especialmente con el método lineal, no era posible dado que debido al método empleado (partición de superficie basada en “triangulación Delaunye”), si se presentaban casos en los grupos de prueba o chequeo similares a los existentes en el grupo de entrenamiento, la salida se computaba como el promedio entre el caso de entrenamiento y el caso a interpolar. La anterior situación generaba resultados “NaN” o no asociados a valor numérico de calificación lo que impedía la correcta evaluación del error porcentual. Esto se solucionó a través de la asignación automática de cero para el error porcentual de estos casos específicos y el descarte de los mismos para el cálculo final del error general en el grupo de casos objeto de evaluación .
- Cálculo del error promedio porcentual final para cada tipo de interpolación.

La tabla No 26 resume los resultados obtenidos con la interpolación multidimensional para los diferentes grupos de datos y métodos de cálculo usados.

Tabla 14. Resumen de resultados de error porcentual final usando técnicas de interpolación multidimensional.

# de Componentes Principales	Datos de Chequeo		Datos de Prueba	
	Método Cercano	Método Lineal	Método Cercano	Método Lineal
1	9.92 %	9.95 %	7.74 %	8.17 %
2	6.12 %	6.43 %	6.11 %	6.90 %
3	6.37 %	6.23 %	5.37 %	5.05 %
4	5.91 %	5.54 %	4.75 %	4.83 %
5	5.28 %	4.836 %	3.16 %	5.33 %

Los resultados obtenidos muestran una reducción del error porcentual final promedio de los dos grupos de datos (calculado como la diferencia porcentual entre la calificación calculada por la técnica de interpolación y la asignada por el grupo de expertos) a medida que se incrementa el número de componentes principales usados en el proceso de interpolación el cual esta asociado a su dimensionalidad.

3.8.4 Implementación de la estrategia de evaluación usando sistemas híbridos neurodifusos. A fin de evaluar el desempeño de la estructura de evaluación bajo una técnica alternativa se realizó el mismo ejercicio anterior usando sistemas híbridos neurodifusos usando la función ANFISEDIT de MATLAB. La implementación se hizo en forma muy similar a la realizada bajo la técnica de interpolación ya que al igual que en esta, se usaron grupos de datos de entrenamiento, prueba y chequeo seleccionados aleatoriamente. Para este caso se verificó el efecto de las diferentes variables que caracterizan el desempeño de un sistema híbrido neurodifusos (número de entradas, número y tipo de funciones de membresía, tipo de función de salida, etc.). La tabla 27 resume las variables que se tuvieron en cuenta en esta evaluación.

Tabla 15. Resumen de variables consideradas en la evaluación de desempeño del esquema bajo sistemas híbridos neurodifusos.

Variable considerada en la evaluación	Rango u opciones
# de entradas (componentes principales considerados)	2 a 6
# de funciones de membrecía	2 a 5
Tipo de funciones de membrecía	“gbellmf” y “gaussmf”
Método de generación del sistema híbrido	“grid partition (división de red)” y “subclustering (subsectorización)”
Tipo de función de salida	“constante” y “lineal”
Método de optimización del entrenamiento	“híbrido (hybrid)” y “retropropagación (backpropagation)”

En general se observó un mejor desempeño del sistema experto neurodifusos cuando se usaron el método de “subsectorización” o “**subclustering**” para la generación de la estructura del sistema híbrido y la técnica “híbrida o hybrid” para la optimización del entrenamiento del sistema. Con la misma técnica de optimización de entrenamiento y el método de generación “división de red” o “**grid partition**” se observaron inestabilidades. Los resultados obtenidos para el error final para las diferentes combinaciones de los parámetros referidos se muestran en la tabla No 28.

Tabla 16. Resumen de resultados de error porcentual obtenido para los diferentes grupos de datos variando diferentes parámetros del sistema híbrido neurodifusos.

# de entradas del sistema de inferencia fuzzy	Método de generación sistema Fuzzy	Método de optimización de entrenamiento sistema Fuzzy	Error porcentual (%)			Niveles de membresía	Tipo de función de membresía	error promedio
			Datos entrenamiento	Datos de Chequeo	Datos de Prueba			
2	Grid Partition	Hibrido	6,25	6,85	5,69	3	gbell lineal	6,26
2	Grid Partition	Hibrido	6,18	6,28	5,64	4	gbell lineal	6,03
2	Grid Partition	Hibrido	5,92	7,73	5,89	5	gbell lineal	6,51
2	Grid Partition	Hibrido	6,64	6,48	5,93	3	gbell constante	6,35
2	Grid Partition	Hibrido	6,27	6,16	5,61	4	gbell constante	6,01
2	Grid Partition	Hibrido	6,25	6,44	5,66	5	gbell constante	6,12
2	Subclustering	Hibrido	6,41	6,5	5,7	4	No aplica	6,20
3	Grid Partition	Hibrido	3,77	7,79	20,12	4	gbell lineal	10,56
3	Grid Partition	Hibrido	5,07	5,76	10,21	3	gbell constante	7,01
3	Grid Partition	Hibrido	4,17	8,82	14,38	3	gbell lineal	9,12
3	Grid Partition	Hibrido	4,34	22,05	34,98	5	gbell constante	20,46
3	Subclustering	Hibrido	4,87	5,27	4,04	3	No aplica	4,73
4	Subclustering	Hibrido	4,64	4,63	3,86	2	No aplica	4,38
5	Subclustering	Hibrido	3,78	3,89	3,55	2	No aplica	3,74
6	Subclustering	Hibrido	3,34 90	3,73	3	2	No aplica	3,36

Las figuras 27 y 28 muestran algunos ejemplos de la evolución del error durante el proceso de entrenamiento usando métodos de generación “**subclustering**” y “**gridpartition**”. Asimismo la figura 30 comparan los resultados obtenidos con el sistema híbrido con los valores con que estos fueron entrenados para un grupo de datos de chequeo.

Figura 27. Error de entrenamiento para sistema híbrido neurodifusos generado por subsectorización.

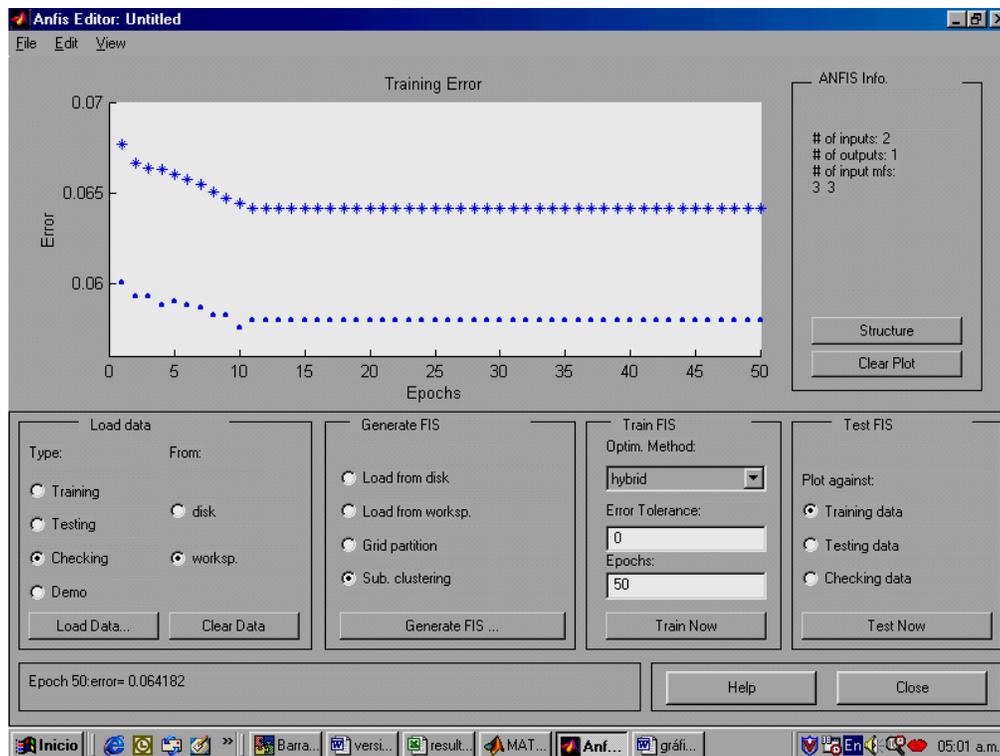


Figura 28. Error de entrenamiento para sistema híbrido neurodifusos generado por partición de red.

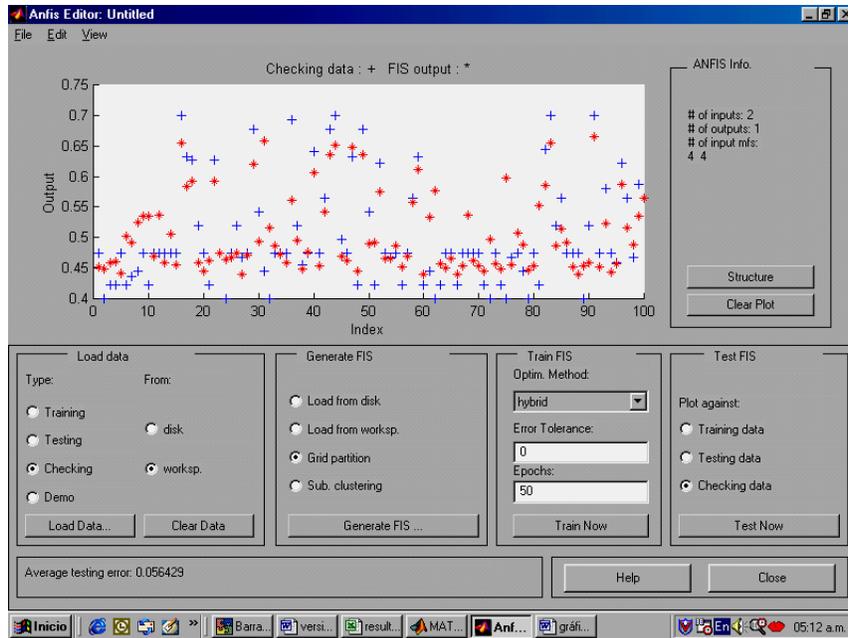
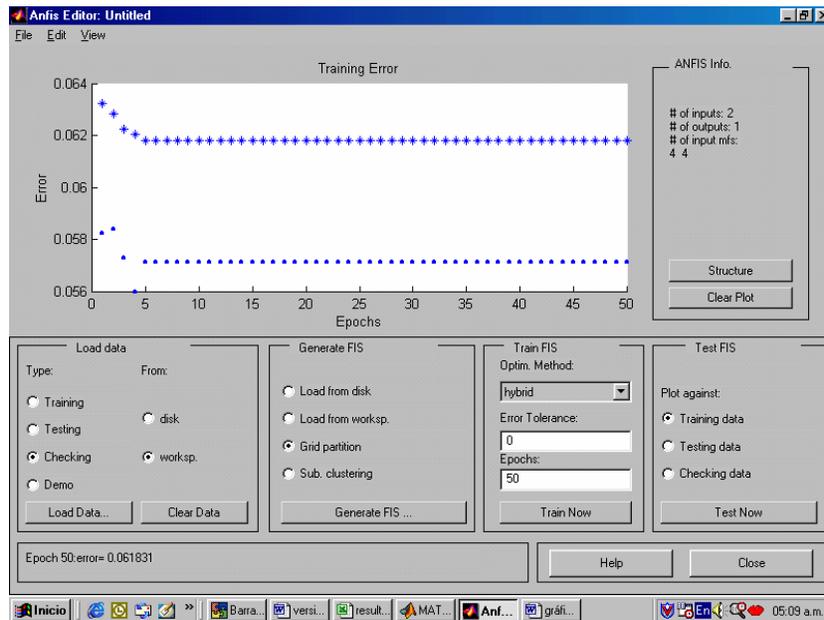


Figura 29. Comparación entre salida de resultados del sistema híbrido y los datos de entrenamiento para el grupo de chequeo en uno de los casos.



Dado que son varios los parámetros que pueden influir el desempeño del sistema híbrido neurodifusos, se trató de identificar la influencia de cada uno de ellos sobre dicho desempeño. Las figuras 30 y 31 muestran el comportamiento del error promedio obtenido usando los grupos de datos de entrenamiento, prueba y chequeo al variar el número de entradas al sistema (relacionado con el número de componentes principales usados) y al variar el número de funciones de membrecía de cada entrada para un número fijo de entradas. El rango de comparaciones es limitado dado que para el método de generación del sistema híbrido por “partición de red” se presentaron bloqueos e inestabilidades en la ejecución del programa al usar mas de tres entradas.

Figura 30. Comportamiento del error promedio obtenido para los diferentes grupos de datos variando el número de entradas.

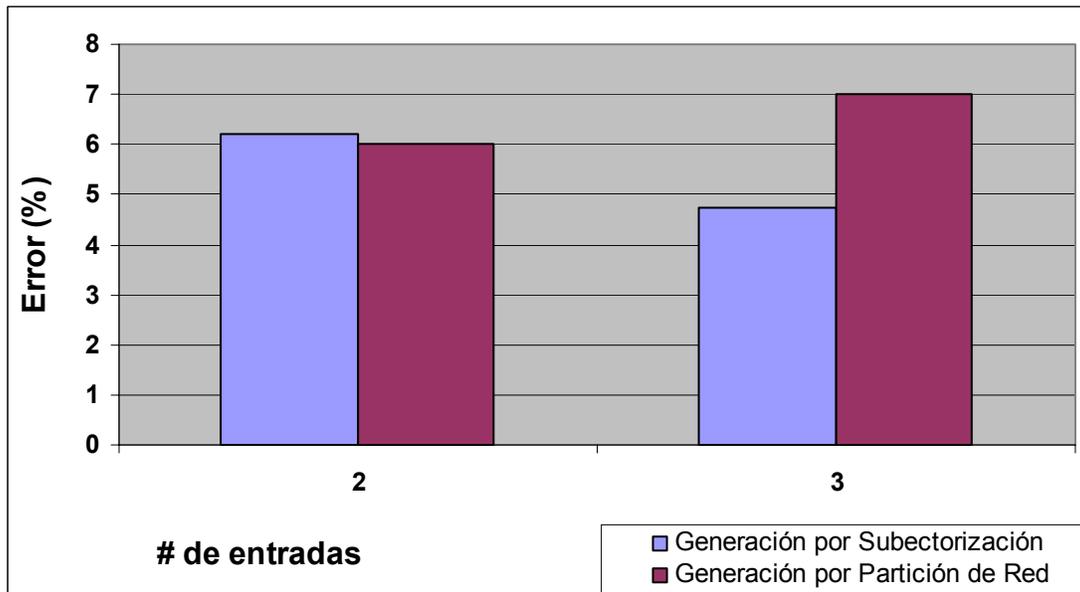
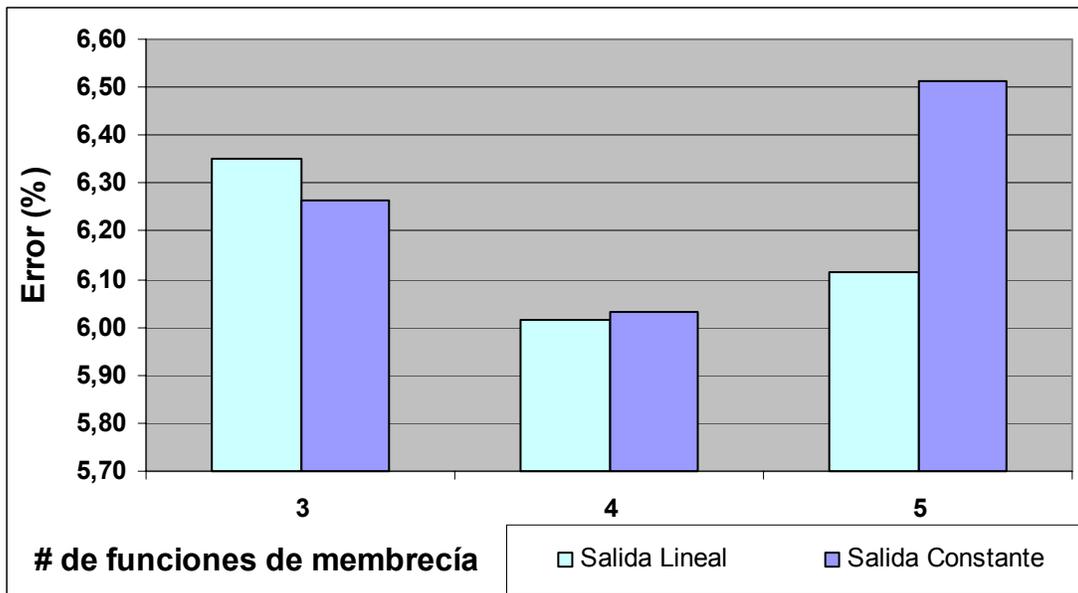


Figura 31. Comportamiento del error promedio obtenido para sistema de generación por “partición de red” variando el número de funciones de membrecía.



Con base en la información obtenida de la tabla de resultados y de los gráficos anteriores se puede decir, entre otras cosas:

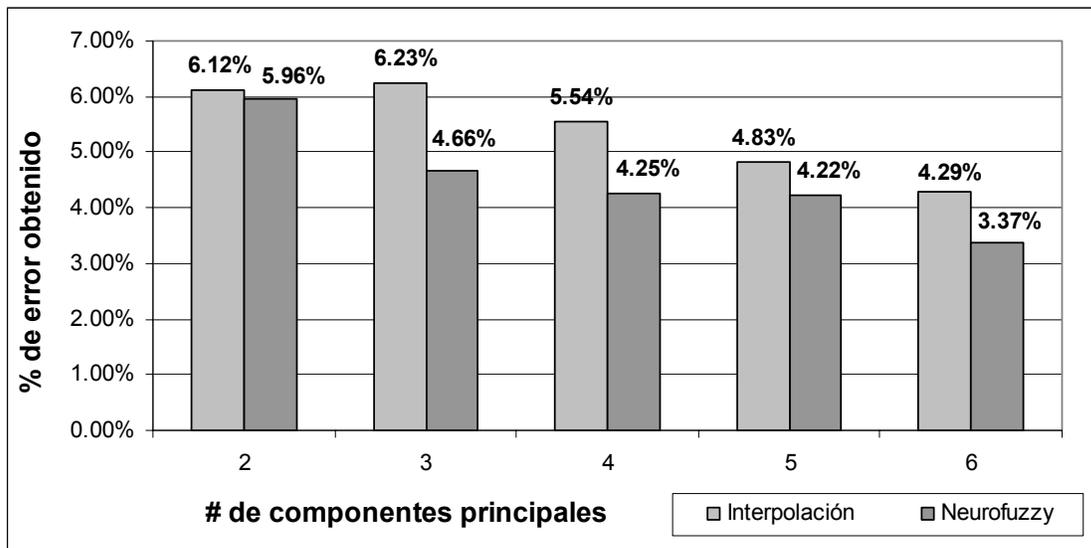
- El incremento del número de entradas del sistema si bien puede reducir el error final en la salida, en algunos casos, especialmente para el método de generación “partición de red”, podría causar inestabilidad en el comportamiento de este haciendo que crezca.
- El incremento de las funciones de membrecía puede mejorar el comportamiento del error promedio hasta cierto punto ya que en la medida en que estas, la estructura y entrenamiento del sistema híbrido se vuelven complejos.
- En general, el mejor comportamiento del error promedio se obtuvo para el método de generación del sistema de “subsectorización” usando la técnica de optimización de entrenamiento “híbrida”. Con la técnica de “retropropagación”

se observaron altos valores en el error promedio final conseguido por lo que no se relacionan sus resultados.

3.9 COMPARACIÓN DE RESULTADOS OBTENIDOS CON LAS DOS TÉCNICAS USADAS

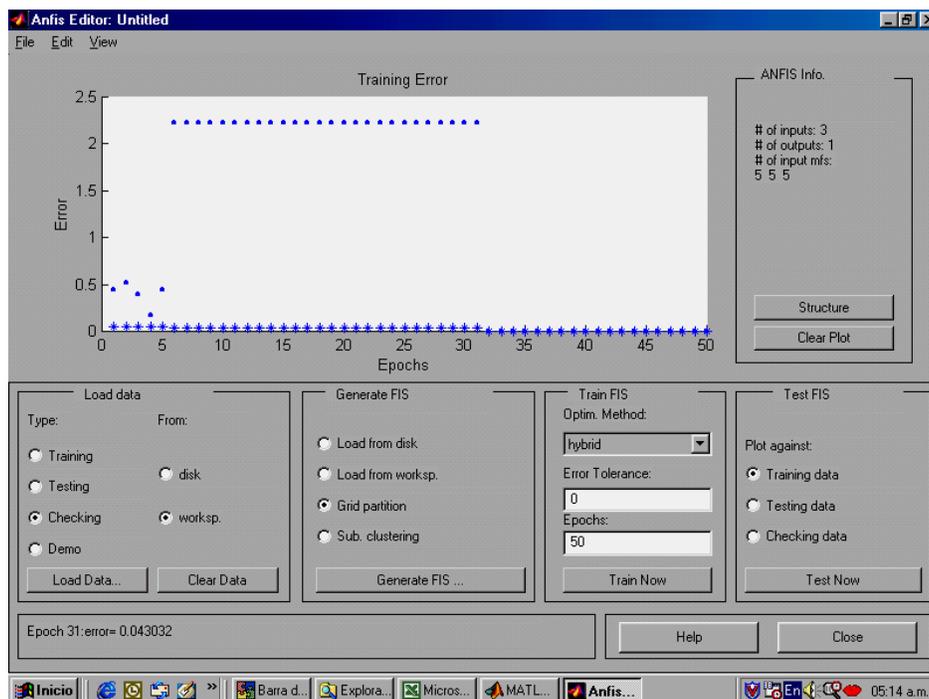
Una vez obtenidos los resultados de la estructura de evaluación bajo cada una de las técnicas (interpolación multidimensional y sistemas híbridos neurodifusos) se procedió a establecer una comparación entre los mismos y así identificar potencialidades de aplicación para cada una de ellas. Para esto, se seleccionó la combinación de parámetros que permitió obtener el menor valor de error promedio en cada caso. La figura 32 resume los resultados obtenidos para cada técnica y con diferente número de componentes principales (dimensiones) considerados.

Figura 32. Comportamiento del error promedio del esquema de evaluación para las dos técnicas consideradas.



De la figura anterior se observa que la tendencia del error promedio en la salida para ambas técnicas es decreciente a medida que aumenta el número de componentes principales considerados, lo que se explica por el mayor porcentaje de información inicial considerado. Asimismo, en ambas técnicas, el incremento de la dimensionalidad del problema genera una mayor complejidad en la estructura de evaluación y un mayor tiempo de procesamiento de la misma, sin embargo, para la técnica híbrida neurodifusa y bajo ciertas combinaciones de parámetros, este incremento implica algunas veces inestabilidad en el proceso de entrenamiento reflejado en la oscilación e incremento del error a medida que se incrementa el número de iteraciones en el proceso de entrenamiento. La figura 33 muestra un ejemplo de este tipo de comportamiento para una estructura híbrida neurodifusa generada por el método de “partición de red” y entrenamiento optimizado bajo método híbrido con 3 entradas y 5 funciones de membresía.

Figura 33. Ejemplo de comportamiento inestable en el proceso de entrenamiento de una red híbrida neurodifusos.



En resumen, la técnica de sistemas híbridos neurodifusos muestra un mejor desempeño general comparado con la interpolación multidimensional para la solución de problemas generales de obtención de información nueva partiendo de información conocida. Sin embargo, se debe tener en cuenta que al incrementarse la dimensionalidad del problema y debido a la complejidad de la estructura formada y bajo ciertas combinaciones de parámetros que definen el método de entrenamiento y el de generación de la estructura de inferencia, se puede llegar a generar inestabilidades en el proceso de entrenamiento de los sistema híbridos que incrementan el error promedio final de la salida.

4. CONCLUSIONES

4.1 GENERALES

Se alcanzaron satisfactoriamente los objetivos propuestos en el presente trabajo.

Se evaluaron las técnicas de interpolación multidimensional y los sistemas de inferencia híbridos neurodifusos para obtener la calificación de condición de nuevos casos a partir de un buen grupo de casos evaluados y conocidos mostrando esta última técnica un mejor desempeño en general. Aunque las nuevas técnicas de inferencia representadas en los sistemas híbridos han sido utilizadas profusamente en los últimos años en la solución de estos problemas típicos como se relaciona en muchos artículos, las técnicas clásicas como la interpolación multidimensional pueden ser una gran alternativa de menor complejidad computacional que la primera y con niveles de error aceptables sobre todo cuando crece la dimensionalidad del problema.

La técnica de Análisis de Componentes Principales para preprocesamiento de los datos se mostró particularmente útil para reducir objetivamente la dimensionalidad del problema conservando gran parte de la información lo que a su vez reduce la complejidad computacional y el tiempo de procesamiento total para lograr la solución del problema.

En resumen, si se tiene un buen grupo de casos previamente evaluado y con un buen cubrimiento del rango de las diferentes variables, es posible resolver nuevos casos tomando como base esta información y usando técnicas sencillas como la interpolación multidimensional. Esto, para el caso de análisis de condición de equipos, no es tan difícil de conseguir especialmente si los criterios de

evaluación de las diferentes variables han sido obtenidos de acuerdo con la historia particular de los equipos objeto de estudio y si el proceso de evaluación se viene desarrollando regularmente y desde tiempo atrás. El preprocesamiento de la información a través de la técnica de Análisis de Componentes Principales puede ayudar a reducir la complejidad del problema y obtener niveles razonables de error en la salida.

4.2 ESPECIFICAS

Dentro de las conclusiones específicas logradas con este trabajo podemos mencionar:

- La técnica de generación del sistema adaptativo híbrido neurodifuso “**subclustering**” o “subsectorización” parece ofrecer mejores resultados que la técnica alternativa de “**grid partition**” o “partición de red”. En la medida que aumenta el número de entradas (dimensiones del problema) el proceso de entrenamiento con esta última puede sufrir oscilaciones e incremento en el error de salida.
- El incremento en el número de funciones de membrecía usado para evaluar las variables de entrada en los sistemas híbridos neurodifusos influye en la reducción del error final. Sin embargo, usar mas de tres funciones de membrecía puede hacer mas complejo el proceso de entrenamiento del sistema híbrido e incrementar el error final a la salida.
- Aunque existen dos técnicas para la optimización del entrenamiento del sistema híbrido neurodifuso, “híbrido” y “retropropagación”, la técnica de optimización de “retropropagación” implica una mayor complejidad en el proceso de entrenamiento y una mayor demanda computacional lo que puede

ocasionar al igual que en el caso anterior, inestabilidad y altos valores en el error final de salida.

- La función de salida del sistema híbrido neurodifuso puede ser configurada como “lineal” o “constante”. Los resultados obtenidos mostraron un ligero mejor desempeño con la segunda demostrado en unos menores valores del error final.
- Se debe continuar mejorando la estructura de evaluación de condición de equipos, especialmente la de transformadores de potencia dada la importancia y costo de los mismos y la complejidad y requerimientos de experiencia involucrados en dicho proceso. La incorporación de un mayor número de variables explicativas de los fenómenos de degradación y desgaste de los equipos, así como la evaluación de mayor cantidad de datos que caractericen la evolución histórica de estas variables implicarán un mayor reto computacional que enfrentará nuevamente al analista de condición de equipos ante la posibilidad de usar las técnicas evaluadas en este trabajo u otras, buscando siempre obtener una solución rápida y efectiva del problema complejo abordado. Específicamente se debe incorporar nuevos aspectos de evaluación de condición de componentes importantes del transformador que no fueron considerados como son el cambiador de tomas bajo carga y los bujes aislantes. También se debe considerar la inclusión de variables que caractericen el desempeño operativo de la unidad y los esfuerzos asociados a dicho desempeño, en un intento de incrementar la extensión del proceso de evaluación de condición y llegar a inferir su evolución a mediano y largo plazo.

BIBLIOGRAFIA

[1] Condition based evaluation of net transformers- Experience from a new ranking procedure; L. Petterson, N.L. Fantana and others; 12-108, CIGRE 2002 Sesion.

[2] Condition Assessment for Transformer Life Assessment, P.A.Payne; Proceedings of the 2002 Doble International Conference.

[3] A scoring system for integrating dissolved gas analysis results in to a life management process for power transformers, J.A.Lapworth; Proceedings of the 2002 Doble International Conference.

[4] Experience with life assessment and refurbishment of 400 kV shunt reactors, V.Sokolov and V.Skrum; Proceedings of the 1997 Doble International Conference.

[5] Analysis of Transformer Failures- A Twenty years trend, W.H. Bartley; Proceedings of the 2000 Doble International Conference.

[6] Transformer Design Principles: with applications to core-form power transformers; R. Del Vecchio, B.Poulin and others; Gordon and Breach Science Publishers, 2001.

[7] Transformerboard I and II; H.P Moser and others; Scientia Electrica; 1979.

[8] Evolution of ABB's Transformer Risk / Life Assessment Process; Ramsis Girgis, Mark Perkins and Aaim Fazlagic; Proceedings of the 2003 Doble International Conference.

[9] Monitoring and Diagnostic of Transformer Solid Insulation; J.P.van Bolhuis and J.J.Smith; IEEE Transactions on Power Delivery, Vol 17, No 2, April 2002.

[10] Ageing, A perspective. Cigre Working Group 17.27.

[11] IEEE Guide for Interpretation of Gases Generated in Oil-Immersed Transformers; Std C57.104-1991.

[12] New Guidelines for interpretation of dissolved gas analysis in oil-filled transformers; A.Mollmann and B.Pahlavanpour on Behalf of Working Group 15.01 Task Force 01; Electra No 186, October 1999; CIGRE.

[13] Artificial Intelligence Applications in the Diagnosis of Power Transformer Incipient Faults; Zhenyuan Wang; Dissertation submitted to the Faculty of the Virginia Polytechnic Institute and State University, 2000.

[14] Multivariate Date Analysis; J.F.Fair, R.E.Anderson, R.L.Tatham, W.C.Black; Prentice Hall International, Fifth Edition, 1999.

[15] Introductory Statistical Analysis; D.L.Harnett and J.L.Murphy; Addison-Wesley Publishing Company Inc; Second Edition; 1980.

[16] Degradation of cellulosic insulation in power transformers. Part 3: Effects of oxygen and water on ageing on oil impregnated paper; A.M.Emsley, X.Xiao, R.J.Heywood and M.Ali; IEE Proc Sci Meas Technol, Vol 147 No 3; May 2000.

[17] Large scale survey of furanic compounds in operating transformers and implications for estimating service life; Jhon R Sans, K. Muge and Joseph J Kelly; Conference Record of the 1998 IEEE International Symposium on Electrical Insulation. Arlington, Virginia, USA, June 7-10, 1998.

[18] Fuzzy Learning Vector Quantization Networks for Power Transformer Condition Assessment; Hong-Tzer Yang, Chiung Chou Liao and Jeng-Hong chou; IEEE Transactions on Dielectrics and Electrical Insulation, Vol 8 No 1, February 2001.

[19] A Novel Fuzzy Logic Approach to Transformer Fault Diagnosis; Syed Mofizul Islam, Tony Wu and Gerard Ledwich; IEEE Transactions on Dielectrics and Electrical Insulation; Vol 7 No 2, April 2000.

[20] Transformer State Assessment: Self-Organizing Maps As An Intelligent On-Line Data Processor; A.Schenk, S.Natale, A.Germond; P.Boss and A.Lam; CIGRE Session 2002, 15-102.

[21] Data Mining of Power Transformer Database Using Self-Organising Maps; K.Obu-Cann, K.Fujimura,H.Tokutaka and others; IEEE 2001.

[22] Condition Based Evaluation of Net Transformers-Experience From A New Ranking Procedure, L.Petterson, J.O.Persson, K.I.Waldén and N.L.Fantana; CIGRE Sesion 2002, 12-108.

[23] Data Mining Techniques to Assess The Condition of High Voltage Electrical Plant; A.J.McGrail, E.Gulsky, E.R.S Groot, T.R Blackburn, D.Allan and D.Birtwhistle; 15-107, Sesion 2002, CIGRE.

[24] Neu-Fuzzy Algorithms for Power Transformer Diagnostics; O. Roizman and V.Davydov; IEEE 2000.

[25] Transformer Fault Diagnosis Using Fuzzy Logic Interpretations; Want Yat How, Marzuki Khalid, Syed Ahmad Fuad Syed Zain; IEEE

[26] Statistical and Neural Network Analysis of Dissolved Gases in Power Transformers; K F Thang, R K Aggarwal, D G Esp and A J McGrail; Dielectric Materials, Measurement and Applications, Conferencia Publication No 473, IEE 2000.

[27] Fuzzy Logic Toolbox for use with MATLAB; Users Guide Version 2, The Mathworks Inc.