



REPÚBLICA DE CUBA  
MINISTERIO DE EDUCACIÓN SUPERIOR  
INSTITUTO SUPERIOR MINERO METALÚRGICO DE MOA  
“Dr. Antonio Núñez Jiménez”

# *Trabajo de Diploma*

**En opción al Título de Ingeniero Eléctrico**

*Título:* *Estimador neuronal para el diagnóstico de fallas en accionamientos con motores de inducción*

*Diplomante:* *Dixan Rosales Almaguer*

*Tutores:* *Dr. C. Luis Delfín Rojas Purón*

*Ing. Ernesto Coello Velázquez*

*Ing. Emilio Santiesteban*

Curso, 2009-2010  
“Año 52 de la Revolución”

## **Declaración de Autoridad**

**Yo: Dixan Rosales Almaguer**

**Autor de este Trabajo de Diploma junto al Dr. Luis Delfín Rojas Purón e ingenieros Emilio Santiesteban y Ernesto Coello Velásquez certifico su propiedad intelectual a favor del Instituto Superior Minero Metalúrgico de Moa "Dr. Antonio Núñez Jiménez" el cual podrá hacer uso de mismo para fines docentes y educativos.**

## ***Pensamiento***

*“Hay una fuerza motriz más poderosa que el vapor, la electricidad y la energía atómica: la voluntad.”*

*Albert Einstein*

## ***Dedicatoria***

*Dedico este trabajo de diploma en especial a mi madre Mayda Almaguer Gutierrez y mi padre Norge Rosales Peña, a mis abuelos que siempre me apoyan, a mis hermanos Arnoldo Rosales Almaguer y Norge Rosales. a toda la familia.*

## *Agradecimientos*

*Agradezco con todo mi corazón a mis padres Mayda Almaguer y Norge Rosales por el sacrificio y confianza depositada en mí para que pudiese lograr lo que soy hoy, a mis abuelos Arnoldo y Ana Rosa Peña por el gran apoyo que me brindan, a los amigos que contribuyeron a que este sueño se realizara.*

*Agradezco a todos los profesores, a mis tutores y de manera muy especial al Dr. Luis Rojas Purón por sus conocimientos brindados para garantizar el éxito en este trabajo.*

*Agradezco a la vida por haberme permitido nacer en esta gran revolución socialista y por darme la oportunidad de forjarme como una persona culta y preparada en la especialidad de Ingeniería Eléctrica.*

## **Resumen**

Teniendo en cuenta las condiciones que presenta el país se realiza esta tesis con el tema estimador neuronal para el diagnostico de fallas en accionamientos con motores de inducción. la cual consta de cinco capítulos que están ubicados de la forma siguiente capítulo I Tipos de fallas en accionamientos con motores de inducción, lo cual está dado por las diferentes regiones del motor donde se ocasionan la falla que afectan el buen funcionamiento de este, el capítulo II está enmarcado en surgimiento de la inteligencia artificial.

El capítulo III se hace una comparación entre una neurona biológica y una artificial, partes que la conforman, los tipos de redes, y funciones de activación, el capítulo siguiente se basa en la utilización de estas redes para diagnosticar las fallas de accionamientos con motores de inducción en la cual se utilizan dos redes, una básica radial y otra de tipo feedforward para el diagnostico de las señales de vibraciones, cavitación y tensión.

## **Summary**

Keeping in mind the conditions that it presents the country is carried out this thesis with the topic neuronal estimator for the diagnose of flaws in workings with induction motors which consists of five chapters that are located in the way following chapter I Types of flaws in workings with induction motors, that which is given by the different regions of the motor where they are caused the flaw that you/they affect the good operation of this, the chapter II it is framed in emergence of the artificial intelligence.

The chapter III a comparison is made between a biological neuron and an artificial one, you leave that conform it, the types of nets, and activation functions, the following chapter is based on the use of these nets to diagnose the flaws of workings with induction motors in which two nets are used, a basic one radial and another of type feedforward for the I diagnose of the signs of vibrations, cavitations and tension.

## Índice

|                                                                                                        |     |
|--------------------------------------------------------------------------------------------------------|-----|
| Declaración de Autoridad.....                                                                          | I   |
| <i>Pensamiento</i> .....                                                                               | II  |
| <i>Dedicatoria</i> .....                                                                               | III |
| <i>Agradecimientos</i> .....                                                                           | IV  |
| Resumen .....                                                                                          | V   |
| Summary .....                                                                                          | VI  |
| Índice.....                                                                                            | VII |
| Introducción general .....                                                                             | 1   |
| Problema científico .....                                                                              | 2   |
| Hipótesis.....                                                                                         | 2   |
| Objetivo .....                                                                                         | 2   |
| <b>Resultados esperados</b> .....                                                                      | 2   |
| Capítulo I Regímenes de fallas en los accionamientos con motores de inducción..                        | 3   |
| 1.1 Introducción .....                                                                                 | 3   |
| 1.2 Herramientas especializadas de Análisis Predictivo en Motores Eléctricos .....                     | 4   |
| 1.3. Métodos .....                                                                                     | 4   |
| 1.4. Zonas de Falla .....                                                                              | 5   |
| <b>1.5 Fallas en Rodamientos.</b> .....                                                                | 7   |
| 1.5.1. Teoría de fallas en rodamientos.....                                                            | 9   |
| 1.5.2. Análisis espectral de corriente.....                                                            | 11  |
| 1.5.3. Análisis por aplicación del Radio del Vector Corriente .....                                    | 12  |
| 1.6. Aislamiento .....                                                                                 | 12  |
| 1.7. Rotor .....                                                                                       | 16  |
| 1.8. Estator.....                                                                                      | 18  |
| 1.9 Conclusiones .....                                                                                 | 20  |
| Capítulo II Fundamentos sobre Sistemas expertos .....                                                  | 21  |
| 2.1 Introducción .....                                                                                 | 21  |
| 2.2 Historia de los sistemas expertos .....                                                            | 21  |
| 2.3. Definición y características de un sistema experto .....                                          | 25  |
| 2.4. Los sistemas expertos.....                                                                        | 25  |
| 2.5. Estructura básica de un sistema experto .....                                                     | 26  |
| 2.6. Principios del sistema experto .....                                                              | 27  |
| 2.7. Arquitectura y funcionamiento de los sistemas expertos .....                                      | 28  |
| 2.8. Arquitectura básica de los sistemas expertos.....                                                 | 30  |
| 2.9. Resumen del funcionamiento de un SE.....                                                          | 31  |
| 2.10 Aplicaciones de los sistemas expertos.....                                                        | 34  |
| 2.11. Uso de los sistemas expertos según el tipo de problema. ....                                     | 35  |
| 2.11.1. Ventajas de los SE: .....                                                                      | 36  |
| 2.11.2. Desventajas de los SE:.....                                                                    | 37  |
| 2.12 Conclusiones. ....                                                                                | 37  |
| Capítulo III Técnicas de inteligencia artificial. ....                                                 | 38  |
| 3.1. Introducción .....                                                                                | 38  |
| 3.2. Similitud entre el sistema nervioso de los animales y las redes neuronales artificiales.<br>..... | 39  |



|                                                                                                                                         |    |
|-----------------------------------------------------------------------------------------------------------------------------------------|----|
| 3.3. ¿Cómo se trabaja con las redes neuronales?.....                                                                                    | 41 |
| 3.3.1 Funcionamiento.....                                                                                                               | 42 |
| 3.3.2. Estructura. ....                                                                                                                 | 44 |
| 3.4. Función de activación.....                                                                                                         | 45 |
| 3.5 Arquitectura de las redes neuronales artificiales.....                                                                              | 48 |
| 3.5.1 Redes neuronales artificiales de propagación hacia delante. ....                                                                  | 48 |
| 3.5.2 Red de Hopfield.....                                                                                                              | 49 |
| 3.5.3 Red neuronal artificial de propagación con retardos de tiempo.....                                                                | 50 |
| 3.5.4 Red neurona artificial de respuesta de impulso finito. ....                                                                       | 50 |
| 3.6. Algoritmo de retropropagación. Consideraciones especiales. ....                                                                    | 51 |
| 3.6.1 Control de la convergencia. Razón de aprendizaje. ....                                                                            | 52 |
| 3.6.2 Regla delta generalizada. Método del momento. ....                                                                                | 53 |
| 3.6.3 Dimensionamiento de la red. Número de neuronas ocultas.....                                                                       | 54 |
| 3.6.4 Datos de entrenamiento. ....                                                                                                      | 54 |
| 3.6.5 Algunas sugerencias para hacer mejor el algoritmo de retropropagación del error. ....                                             | 56 |
| 3.7. Factores que afectan el entrenamiento en las redes neuronales. ....                                                                | 59 |
| 3.7.1 Los parámetros de función de activación sigmoidea.....                                                                            | 59 |
| 3.7.2 El factor de aprendizaje. ....                                                                                                    | 61 |
| 3.7.3 Regla de aprendizaje Delta-Bar-Delta.....                                                                                         | 62 |
| 3.7.4 El factor momento “momentum”. ....                                                                                                | 62 |
| 3.7.5 Inicialización.....                                                                                                               | 63 |
| 3.7.6 Método de validación cruzada.....                                                                                                 | 63 |
| 3.8. Entrenamiento de las redes neuronales artificiales. ....                                                                           | 64 |
| 3.9. Implementación de las redes neuronales. ....                                                                                       | 67 |
| 3.10. Ventajas. ....                                                                                                                    | 69 |
| 3.11. Aplicaciones.....                                                                                                                 | 69 |
| 3.12. Conclusiones parciales. ....                                                                                                      | 70 |
| Capítulo IV Implementación del estimador neuronal para el diagnostico del accionamiento .....                                           | 72 |
| 4.1 Introducción. ....                                                                                                                  | 72 |
| 4.2 Patrones cognoscitivos de una red neuronal obtenidos a través de las principales zonas de fallas con ayuda del software Matlab..... | 72 |
| 4.2.1 Patrones tensión, corriente, temperatura y potencia del motor de inducción. ...                                                   | 74 |
| 4.3 Patrones frecuencia (vibraciones), obtenidas para el accionamiento del motor de inducción acoplado a una bomba centrifugas.....     | 84 |
| 4.4 Conclusiones.....                                                                                                                   | 93 |
| Capitulo V Evaluación Técnico-Económica .....                                                                                           | 94 |
| 5.1 Introducción.....                                                                                                                   | 94 |
| 5.2 Valoración económica.....                                                                                                           | 94 |
| 5.3. Conclusiones.....                                                                                                                  | 97 |
| Recomendaciones .....                                                                                                                   | 97 |
| Bibliografía.....                                                                                                                       | 98 |

## **Introducción general**

Hoy en día los accionamientos con motores de inducción resultan en la mayoría de los casos más ventajosos que los accionamientos de corriente continua.

Las redes neuronales artificiales se usan profusamente para el reconocimiento de imágenes y sonidos, para el procesamiento de datos señales, para identificar y diagnosticar fallas o averías en un sistema.

Actualmente, existen expectativas muy prometedoras para su aplicación en el campo de la eléctrica y en los sistemas de control de accionamientos. Estas expectativas son las que nos han llevado a tratar de reemplazar algunas partes de los sistemas de monitoreo y control, por un sistemas basados en redes neuronales artificiales.

El presente estudio consiste en ofrecer algunas herramientas para diagnosticar y predecir el comportamiento de un accionamiento con motores de inducción. Para esto se determinaron patrones a partir de mediciones reales, utilizando la técnica de redes neuronales.

## **Problema científico**

La necesidad de conocer las causas que provocan las frecuentes averías en los accionamientos con motores de inducción, ocasionada por diversas causas en las condiciones de explotación minero metalúrgicas de Moa.

## **Hipótesis**

Con la caracterización de los regímenes de trabajo de los motores de inducción y la identificación de las variables que definen el estado técnico de estos accionamientos, es posible entonces elaborar un programa experto que permita diagnosticar los eventos de fallas en estas máquinas

## **Objetivo**

Proponer un programa experto para el diagnóstico inteligente de accionamientos con motores de inducción a partir de varios criterios usando la inteligencia artificial.

## **Resultados esperados**

- Elaborar la matriz de variables que participan en la evaluación de fallas en los accionamientos con motores de inducción en la planta de lixiviación de la empresa Cmte. Ernesto Che Guevara de Moa.
- Ofrecer un programa experto para la evaluación inteligente de fallas a partir de varios criterios utilizados internacionalmente
- Brindar una base experimental bien ordenada que permita elaborar un sistema inteligente de diagnóstico de fallas.
- Desarrollar un caso de estudio para la validación del sistema experto para la de evaluación de fallas en motores de inducción.

# **Capítulo I Regímenes de fallas en los accionamientos con motores de inducción.**

## **1.1 Introducción**

La mayor parte del consumo de energía eléctrica en la industria se debe al uso de los motores eléctricos porque así lo demuestran las estadísticas de países industrializados. Con base en lo anterior, sabemos que los motores eléctricos consumen alrededor del 62% del total de la energía generada y más del 75% de la suministrada a las industrias.

La aplicación de técnicas predictivas especializadas en motores/generadores eléctricos tiene como propósito principal el poder detectar fallas en las máquinas eléctricas rotatorias de forma tal que las interrupciones en la producción debido a fallas inesperadas sean reducidos al máximo (nivel de confiabilidad). Dichas fallas en equipos críticos conducen a pérdidas económicas considerables a nivel de la industria ya que ocasionan interrupciones en la producción durante el lapso de tiempo de una reparación costosa o en el peor de los casos hasta que el equipo sea sustituido, lo cual agrava la situación cuando no se cuenta con un reemplazo inmediato de un equipo costoso.

En estudios efectuados por el Instituto EPRI (Electrical Power Research Institute) en los Estados Unidos en conjunto con la firma General Electric revelan que el mayor porcentaje de incidencia de falla en motores/generadores eléctricos (41%) tiene como causa raíz defectos de tipo eléctrico, aun cuando una falla mecánica es la causa aparente.

## **1.2 Herramientas especializadas de Análisis Predictivo en Motores Eléctricos**

El equipo analizador MCEmax efectúa pruebas predictivas no destructivas en motores/generadores eléctricos. No destructivas y no intrusivas significa que tanto las pruebas estáticas (maquina des energizada) y las pruebas dinámicas (maquina energizada) no van a dañar ni a afectar el funcionamiento integral de la maquina.

Todos los procedimientos de pruebas y los rangos de los parámetros medidos se basan en estándares de prueba de IEEE así como una base de datos incluida en el software de los diferentes fabricantes de motores eléctricos. El análisis efectuado con MCEmax utiliza el concepto de análisis de seis zonas de falla en la maquina eléctrica.

## **1.3. Métodos**

Uno de los métodos que usamos para detectar defectos en el circuito de potencia en un motor / generador, trifásico es la medición de resistencia entre fases, es una prueba estática con motor detenido. En un equipo en buen estado las tres lecturas entre las fases deberían ser casi idénticas, su des balance resistivo debe ser menor a un 5%. Dinámicamente, con motor energizado el circuito es evaluado completamente al detectarse des balances de voltaje en cualquiera de las fases. Otro de los métodos utilizados para complementar el diagnostico del circuito de potencia es la termografía IR, sin duda una de las técnicas más conocidas para detectar falsos contacto.

| AC Standard      |             | Polarization Index |
|------------------|-------------|--------------------|
| Test Date        | 05/15/2001  | 05/15/2001         |
| Test Time        | 02:09:04 PM | 02:15:33 PM        |
|                  | Baseline    |                    |
| Frequency        | 1200        | 1200               |
| Mohm Ph 1 to Gnd |             |                    |
| Charge Time      | 30          | 30                 |
| Voltage          | 500         | 500                |
| Motor Temp       | 40          | 40                 |
| Measured Mohm    | 97.6        | 97.8               |
| Corrected Mohm   | 97.6        | 97.8               |
| pF Ph 1 to Gnd   | 9760        | 9500               |
| ohm Ph 1 to 2    | 1.08900     | 0.75600            |
| ohm Ph 1 to 3    | 0.75600     | 0.75650            |
| ohm Ph 2 to 3    | 1.19250     | 0.75600            |
| mH Ph 1 to 2     | 4.260       | 4.220              |
| mH Ph 1 to 3     | 3.880       | 3.900              |
| mH Ph 2 to 3     | 3.915       | 3.865              |
| Avg. Inductance  | 4.016       | 3.995              |
| % Res. Imbalance | 25.41       | 0.04               |
| % Ind. Imbalance | 6.01        | 5.63               |
| \$ Power Loss    | 76.53       | 0.03               |
| Test Location    | Top OL      | Top OL             |
| MCE #            | 030453      | 030453             |
| User             |             |                    |




Figura1: Desbalance resistivo – falso contacto severo.

### Métodos de detección de fallos.

Existen diferentes métodos invasivos y no invasivos para la detección de fallos utilizando técnicas de análisis de datos de origen eléctrico, mecánico o químico, entre los cuales se pueden resaltar los siguientes: análisis de vibraciones, análisis de temperatura, estimación de parámetros electromagnéticos del motor, análisis de partículas de aceite, análisis de señal de corriente del motor (MCSA).

En el Tabla 1 se realiza una comparación entre los principales métodos de detección de fallos, indicando las fallas que los mismos pueden detectar.

| Método      | Falla que puede detectar |                  |                 |             |
|-------------|--------------------------|------------------|-----------------|-------------|
|             | cortocircuito en estator | Rotura de barras | Excentricidades | Rodamientos |
| Vibración   | NO                       | SI               | SI              | SI          |
| MCSA        | SI                       | SI               | SI              | SI          |
| Temperatura | SI*                      | NO               | NO              | SI*         |
| Partículas  | NO                       | NO               | NO              | SI          |

\* Posibilidad de indicar indicio de falla

### 1.4. Zonas de Falla

#### I. Circuito de Potencia

Generalmente se establece desde el Centro de Control del Motor (CCM) hasta la caja de bornes del mismo, e involucra a todos los conductores con sus bornes,

interruptores, protecciones térmicas, fusibles, contactores y cuchillas. La grafica 2 muestra un típico circuito de potencia, se ha demostrado por EPRI que los falsos contactos han sido la fuente de un 46% de las fallas en motores, por lo que aunque muchas veces el motor este en excelente estado, este se instala en un circuito de potencia defectuoso, que a la postre lo daña.

Los problemas de conexiones de alta resistencia (se oponen al paso de la corriente) son variados, entre ellos,

- Generación de armónicas
- Des balances de voltaje
- Des balances de corriente




Figura 2: Típico circuito de potencia.

Cuando los voltajes de línea aplicados a un motor no son equilibrados se desarrollan corrientes desbalanceadas en los devanados del estator, a estas se les conoce como corrientes de secuencia negativa y reduce el troqué del motor. Se producen dos efectos importantes, aumenta la temperatura en el devanado y aumenta su vibración. Un aumento de la temperatura por encima de su valor permitido provocaría danos al aislamiento, y el aumento en los niveles de vibración provocaría en algún grado solturas mecánicas, desgaste en los rodamientos y aflojamiento de las bobinas. Con des balances de voltaje presentes, la potencia de placa de un motor debe ser multiplicado por un factor de reducción tal y como se observa en la con des balances de voltaje presentes, la potencia de placa de un motor debe ser multiplicado por un factor de reducción tal y como se observa en la figura 3.




Figura 3: Factor de reducción de potencia (NEMA).

La figura 3 muestra un estudio realizado entre el Electric Power Research Institute (EPRI) y General Electric en 1985. El propósito de este estudio fue el mostrar las verdaderas fuentes de falla en motores eléctricos.

Entonces nos preguntamos, estamos realmente diagnosticando todas las zonas posibles de falla en un motor. Realmente la respuesta es simple, ni vibraciones, ni un ohmímetro ni un megger logran revisar todas las zonas de falla de un motor, entonces, la tecnología predictiva que está aplicando en su planta es suficiente para evaluar todos los componentes que pueden causar la falla de un motor.

Las pruebas eléctricas aplicadas a un motor deben de ser confiables y nos deben dar un diagnostico completo de todas las zonas o áreas de falla de un motor. Las pruebas a realizar deben incluir pruebas tanto con motor energizado como con motor detenido (ensayo de corriente directa y ensayo con rotor cortocircuitado). Las pruebas con motor detenido son de particular importancia en aquellos casos en que un motor se este disparando y su puesta en funcionamiento puede terminar de dañarlo, o en el caso de pruebas de puesta en marcha al instalarse un nuevo equipo de producción. Para el diagnóstico de un motor, se han establecido las siguientes zonas o áreas de fallas.

### **1.5 Fallas en Rodamientos.**

Toda máquina rotativa posee partes móviles, por ello requiere algún elemento que permita el movimiento de dichas partes con respecto a las partes fijas.



Los rodamientos son elementos destinados a cumplir esta función produciendo pérdidas de rozamiento tan pequeñas como sea posible para que no se reduzca el rendimiento de la máquina, debiendo absorber todo tipo de vibraciones entre las partes de la máquina. En el caso de los motores, sus rodamientos tienen la función adicional de transmitir a la carcasa los esfuerzos de la carga en el eje, por esto son elementos de vital importancia para la máquina. Como consecuencia del continuo movimiento y esfuerzo a los que están sometidos, los rodamientos son los componentes de mayor índice de falla del motor. Las estadísticas varían de acuerdo a los autores pero la distribución de las fallas es en general la mostrada en la Figura 4.

Dentro de las fallas más frecuentes que afectan a los rodamientos, las más comunes son las siguientes (SIEMENS A&D SD CS Service Cooperation 1995, FAG SOUTH EAST ASIA PTE LTD 2002). Marcas o rayas oblicuas sobre la pista externa o interna y sobre los rodillos o bolas:

Este tipo de marcas aparece habitualmente cuando la máquina se encuentra detenida, ya sea por almacenamiento o cuando se instala como respaldo pero no se pone en marcha hasta que la máquina principal se avería o el sistema lo requiere. Durante estos períodos de reposo, la máquina está sometida a vibraciones que, por no existir una película de lubricante sobre las partes, originan las marcas. Micro corrosión de la pista externa: Este es un proceso que tiene lugar como consecuencia de las vibraciones durante el funcionamiento de la máquina. Pista interna deteriorada: Este fenómeno puede ocurrir cuando se somete a rodamiento a carga radial excesiva, por las vibraciones presentes en la operación, por incorrecta lubricación o simplemente por haberse superado el tiempo de vida útil del rodamiento sin que este se haya remplazado. Marcas o rayas de pequeña magnitud: En este caso, sobre las pistas aparecen marcas que se producen por la circulación de corriente a través del rodamiento a causa de una falla de aislamiento de la máquina. Marcas o rayas de pequeña magnitud: En este caso, sobre las pistas aparecen marcas que se producen por la circulación de corriente a través del rodamiento a causa de una falla de aislamiento de la máquina.

Este tipo de falla puede resultar de la evolución de alguna de las anteriores y dada su magnitud, su aparición pone en riesgo la máquina, por lo que es muy importante detectarla a tiempo. Esta falla puede aparecer además por una carga radial excesiva del rodamiento o simplemente por haberse superado el tiempo de vida útil del rodamiento sin que este se haya remplazado.

Esta falla puede aparecer además por una carga radial excesiva del rodamiento o simplemente por haberse superado el tiempo de vida útil del rodamiento sin que este se haya remplazado.

Rotura de jaula o rejilla: Este tipo de falla puede ocurrir como consecuencia de haberse superado el período o vida útil del rodamiento.

Esta falla introduce restos de material en las pistas, dificultando la circulación de las bolas o los rodillos, lo cual puede llevar a la máquina al estado de rotor calado. Por esta razón es recomendable detectarla cuando se encuentra en estado prematuro para remplazar oportunamente el rodamiento.




Figura 4: Estudio de Fallas en Motores Eléctricos.

#### **1.5.1. Teoría de fallas en rodamientos.**

Las investigaciones realizadas (Silva, Márquez Cardoso, 2005); SIEMENS A&D SD CS Service Cooperation, 1995; FAG SOUTH EAST ASIA PTE LTD, 2002)

permiten caracterizar a las fallas en los rodamientos conociendo el estado de cuatro de sus elementos componentes. Para ello se emplean cuatro ecuaciones, cada una de las cuales dan como resultado una frecuencia característica cuya amplitud se incrementa con el incremento de la magnitud de una falla presente en dichos elementos. Estas ecuaciones dependen de la geometría del rodamiento, el número de bolas o rodillos y la velocidad de rotación del rodamiento. Cabe destacar que estas ecuaciones se pueden aplicar tanto a rodamientos con elementos cilíndricos (rodillos) como a bolas

A continuación se presentan las ecuaciones correspondientes a las frecuencias características de cada uno de los elementos del rodamiento y la zona a la que se asocian.

$$\begin{array}{l} \text{Pista} \\ \text{interna} \end{array} \quad F_{fpi} = \frac{N_b}{2} \times n \times \left( 1 + \frac{D_b \times \cos(\beta)}{D_c} \right) \quad (1)$$

$$\begin{array}{l} \text{Pista} \\ \text{externa} \end{array} \quad F_{fpe} = \frac{N_b}{2} \times n \times \left( 1 - \frac{D_b \times \cos(\beta)}{D_c} \right) \quad (2)$$

$$\text{Bola} \quad F_{fb} = \frac{D_c}{D_b \times 2} \times n \times \left( 1 - \left( \frac{D_b \times \cos(\beta)}{D_c} \right)^2 \right) \quad (3)$$

$$\text{Jaula} \quad F_{fje} = \frac{n}{2} \times \left( 1 - \frac{D_b \times \cos(\beta)}{D_c} \right) \quad (4)$$

La aparición de fallas en rodamientos ha llevado a los especialistas a realizar numerosas investigaciones, de las cuales han surgido gran cantidad de métodos de detección predictiva de fallas incipientes, sin embargo sólo uno de ellos ha encontrado gran implementación, al menos en el ámbito industrial en el que se requieren métodos de costos reducidos y de resultados, sin embargo sólo uno de ellos ha encontrado gran implementación y de resultados satisfactorios.

**Este método**, denominado Análisis de Vibraciones, se basa en el análisis de las velocidades y aceleraciones mecánicas adicionales que aparecen en el motor cuando éste se encuentra en condiciones de falla.

Para llevar a cabo las mediciones de vibraciones, es necesario instalar sobre la carcasa del motor en cuestión al menos un sensor, que envía la señal a un registrador para luego ser analizada. Si bien este método es directo y de alta confiabilidad en la detección de alteraciones, es necesario tener acceso y estar en contacto directo con el motor para efectuar las mediciones.

Esto representa serios inconvenientes cuando se trata de motores instalados en ambientes especiales, como es el caso de las bombas de refrigeración de reactores nucleares, que pueden estar expuestas a radiación, o las bombas empleadas para impulsar arrabio, situadas en ambientes de elevada temperatura. Algunos de los tipos de fallas presentes en los rodamientos pueden detectarse por análisis de la FFT del Radio del Vector Corriente, siempre y cuando su estado no sea muy prematuro. En este sentido, debe tenerse en cuenta el grado en que la pista del rodamiento se ve afectada por la presencia de la falla.

La teoría para encontrar las frecuencias de falla es muy precisa, ya que los valores de frecuencias de falla que aparecen en el espectro de la FFT del Radio del Vector Corriente se pueden determinar con mucha exactitud a través de las ecuaciones, facilitando la búsqueda en dicho espectro. La técnica se puede aplicar a aquellos motores de difícil acceso o de aplicaciones especiales, sin necesidad de que el personal esté en contacto con la máquina. El procedimiento puede aplicarse a motores de cualquier tamaño y potencia siempre y cuando se conozcan los datos de placa del mismo y la geometría

de sus rodamientos de lo cual depende la aplicabilidad o no del método.

### **1.5.2. Análisis espectral de corriente**

Un método alternativo para realizar el mantenimiento predictivo de máquinas rotativas, consiste en el análisis espectral de las corrientes del motor. En éste se considera que la presencia de ciertas excentricidades o defectos en los rodamientos de la máquina, producen, durante la rotación de la misma, cambios

en las impedancias características de la máquina con la consecuente aparición en el espectro de corriente, de señales a frecuencias dadas por:

$$F = F_s \pm (K \times f_n)$$

Donde:

$f_s$ : frecuencia de alimentación del motor [Hz]

$f_n$ : frecuencia dada por las ecuaciones (1) a (4) [Hz]

$k$ : valor entero (1, 2, 3 ...)

Este método responde a muchos de los requerimientos antes mencionados, sin embargo, la magnitud de las señales a frecuencias de falla es tan pequeña que no pueden percibirse con facilidad.

### **1.5.3. Análisis por aplicación del Radio del Vector Corriente**

Otro de los métodos propuestos es el análisis del módulo del vector corriente o vector de Park (Silva, Marquez Cardoso, 2005).

Este vector es el que se obtiene de proyectar los tres vectores que representan las corrientes por las fases sobre dos ejes, denominados  $D$  i  $Q$  i respectivamente en cuadratura entre sí (Fitzgerald, et al., 2004).

### **1.6. Aislamiento**

Cuando hablamos de la condición de aislamiento nos referimos a la resistencia que existe entre este a tierra (RTG, en ingles). La RTG indica que tan limpio o sano esta un aislamiento. Para que se dé una falla a tierra, deben de ocurrir dos cosas. Primero debe crearse un camino de conducción a través del aislamiento. Conforme el aislamiento envejece se fisura y posibilita que se acumule material conductor. Segundo, la superficie exterior del aislamiento se contamina de material conductor y conduce suficiente corriente a la carcasa o núcleo del motor que está conectado a tierra.

Hoy en día los sistemas de aislamiento han mejorado notablemente y son capaces de soportar mayores temperaturas sin sacrificar su vida esperada.

La máxima temperatura de operación de un motor / generador depende principalmente de los materiales usados en su construcción, existen varias clases, pero las más usadas son:

- Aislamiento clase B, temperatura máxima 130°C
- Aislamiento clase F, Temperatura máxima 155°C
- Aislamiento clase H, temperatura máxima 180°C

Dichas temperaturas máximas, son a las cuales el aislamiento podría colapsar.

En termografía IR es posible detectar una falla en el aislamiento de un motor si se tiene la clase de aislamiento del mismo (dato de placa).

Generalmente al medir la temperatura de la carcasa del motor, asumimos que el aislamiento esta en 20°C más alto que esta. Por ejemplo, si observamos que la temperatura de la carcasa de un motor clase B es de 120°C, podría estar muy seguro que la temperatura del aislamiento esta a por lo menos 140°C excediendo la temperatura máxima permitida para esa clase de aislamiento.

El aislamiento pierde muy rápido sus propiedades al aumentar la temperatura, este mismo motor en vez de durar aproximadamente 15 años, duraría alrededor de 3 años.

La termografía IR es una herramienta muy útil para detectar un sobrecalentamiento en el motor, y aunque podría precisar el área donde se produce el calentamiento (corto entre espiras), sin embargo es todavía bastante limitada en su capacidad de indicar el porqué se produce este.




Figura 5: Medición de aislamiento corregida con Temperatura.

El determinar la causa raíz de una falla en el aislamiento de un motor, puede involucrar alguno de estas causas posibles:

- Circuito de potencia: Una conexión de alta resistencia, produce un voltaje de línea des balanceada.
- Armónicas: que introducen corrientes de secuencia negativa y sobrecalentando el devanado.

El determinar la causa raíz de una falla en el aislamiento de un motor, puede involucrar alguno de estas causas posibles.

- Ambiental: Contaminación en el motor.

Es fácil diagnosticar una falla en el aislamiento de un motor, pero se deberá realmente por esto?. Si se instala nuevamente el motor reparado o uno nuevo, es muy probable que la falla se repita. El utilizar un megger es un buen inicio para probar el aislamiento eléctrico pero no da información completa, otro aspecto importante de resaltar es que el Institute de Ingeniería Eléctrica y Electrónica (IEEE) basa los límites de aislamiento a una temperatura de 40°C.

Por ello es muy importante hacer lectura con corrección de temperatura, de otro modo se tendrían valores con variaciones altas y bajas, tal y como se observa en la figura 5.

La norma de la IEEE a la que hacemos referencia es la IEEE 43-2000.

También IEEE indica que se debe de calcular el Polarization Index (PI), es el valor de aislamiento tomado a los 10 minutos entre el valor de 1 minuto, básicamente da una indicación de la pendiente del perfil del índice de polarización; un PI de 2.0 según IEEE es aceptable para aislamientos clases B, F y H; pero desdichadamente motores / generadores con sistemas de aislamiento inestables pueden dar valores cercanos a 2.0; por esto recomendamos el evaluar el perfil del índice de aislamiento y no solo su valor.




Figura 6: Perfil del índice de polarización inaceptable.

La figura 6 muestra el perfil para un motor con una contaminación severa y posible daño o resquebrajamiento del aislamiento. La prueba del PI (**índice de polarización**) es una prueba que se realiza con voltaje CD y no es potencialmente destructiva como lo son otro tipo de pruebas como Hi-Pot y la prueba de Impulso, que se utilizan también para este efecto. Otro tipo de parámetro utilizado para evaluar la contaminación interna del aislamiento es la Capacitancia a tierra (CTG, en inglés).

Una máquina que está limpia y seca exhibe un CTG bajo en comparación con una que está contaminada. Un aumento en la contaminación es comparable con el aumento en el material dieléctrico entre las dos placas de un capacitor, conforme se deposite más material en el aislamiento el dieléctrico aumenta y la Capacitancia crece.



Para aquellas compañías que efectúan paros para limpieza de motores esta es una herramienta de gran importancia para ahorrar tiempo de paro para este tipo de mantenimiento.

### **1.7. Rotor**

Cuando nos referimos a la condición de un rotor se deben de revisar; las barras, laminaciones y los anillos de corto circuito. Un estudio del EPRI mostró que un 10% de fallas en motores se debió al rotor. Una barra rota genera un calor intenso en la zona de ruptura y puede destruir el aislamiento cercano a las laminaciones y el devanado estático colapsara.

Desdichadamente, muchas veces, los problemas en las barras del rotor no son fácilmente detectables con tecnologías comunes y se obvia como causa-raíz. Hemos tenido la experiencia de muchas empresas que rebobinan varias veces un motor sin saber que la raíz del problema en el devanado estaba en el rotor.

El MCEmax detecta un problema en el rotor mediante la prueba del Rotor Influence Check (RIC), esta prueba es estática y relaciona el magnetismo entre el rotor y el estator.

La prueba se realiza al rotor en incrementos específicos (determinados por el número de polos del motor) y tomando la lectura en el cambio de inductancia para cada fase. El RIC de un motor normal tiene la forma de la figura 8 y el RIC de un rotor con barras rotas muestra valores de inductancia erráticos y periódicos causados por la distorsión del flujo alrededor de la barra rota.

Se recomienda efectuar la prueba del RIC como prueba inicial para un motor en su primer análisis.




Figura 7: RIC - rotor en buen estado.




Figura 8: RIC rotor con barras rotas.




Figura 9: Prueba dinámica - falla en rotor.

Dinámicamente se identifica las barras rotas en un análisis de corriente del motor, este se desarrolla al tomar la señal corriente de las tres fases del motor y se pasa al dominio de la frecuencia (FFT).

El análisis dinámico identifica una falla en el rotor como una banda lateral, a la frecuencia de línea a una frecuencia llamada frecuencia de paso de polo (FP).

Al utilizar tanto el análisis estático como dinámico para diagnosticar un problema en un rotor se tiene un alto nivel de confianza, especialmente cuando se tiene que sacar un motor importante de servicio.

La figura 9 muestra problema en un rotor obtenido mediante un análisis de corriente.

### **1.8. Estator**

En un estator es importante el diagnosticar: los devanados, el aislamiento entre vueltas, juntas de soldado entre las espiras y el núcleo del estator o laminaciones. Tal vez, la falla más común es un corto entre vueltas, esto reduce la habilidad de producir un campo magnético balanceado. Esto a la vez trae otras consecuencias como un aumento en la vibración de la máquina, y por ende degradación del aislamiento y daños a los rodamientos del motor. Generalmente este tipo de cortos aumenta la temperatura y el corto se expande a un corto entre espiras y eventualmente destruye todo el motor. Aún más grave que esta es la falla entre fases, un corto de este tipo acelera rápidamente la destrucción del motor.

Fallas de este tipo pueden ocurrir varias veces en un motor y no resultan en una falla a tierra. Debido a esta razón, el utilizar solamente un megger como herramienta predictiva es insuficiente ya que este tipo de fallas pueden ser pasadas por alto.

Sí el núcleo del motor se llegase a dañar el reemplazo del motor sería total. El diagnóstico de esta zona de falla puede ser efectuada directamente en los terminales del motor o desde el Centro de Control de Motores (CCM). La prueba estática involucra mediciones de inductancia entre fases, para esto se envían señales de CA a alta frecuencia, y se calcula un des balance inductivo. Un des balance presente implica que las fases producen campos magnéticos des balanceados y que muy probablemente tiene cortos entre vueltas o espiras. También como parte de la prueba se toman valores de resistencia, si excede un valor predeterminado indica que pueden existir conexiones de alta resistencia en el circuito hacia el motor o en las juntas de soldado.

La siguiente muestra gráficamente el efecto en un devanado en estrella. La prueba dinámica con motor energizado identifica una falla en el estator tomando mediciones de voltaje y corriente por fase y calculando la impedancia en cada una. Si una fase tiene problemas en los devanados, el des balance de impedancia aumenta.




Figura 10: Des balance inductivo - corto entre espiras.

La prueba dinámica con motor energizado identifica una falla en el estator tomando mediciones de voltaje y corriente por fase y calculando la impedancia en cada una. Si una fase tiene problemas en los devanados, el des balance de impedancia aumenta.

### **1.9 Conclusiones**

- El diagnosticar el problema en un motor debe involucrar todas las zonas de falla presentes como lo son: calidad de energía, circuito de potencia, aislamiento, estator, rotor y excentricidad, para ello deben de utilizarse tanto tecnologías dinámicas como estáticas. Y estas deben de ser de tipo no destructivas para no acelerar el daño en el motor.
- El equipo MCEmax fabricado por PdMA puede ser utilizado como herramienta para el diagnóstico de todas las zonas de falla en un motor eléctrico.
- La tecnología estática es la más recomendable para revisar aquellos motores averiados por fallas frecuentes o en aquellos casos que han sido reparados en un taller.

# Capítulo II Fundamentos sobre Sistemas expertos.

## 2.1 Introducción

Los sistemas expertos son programas que reproducen el proceso intelectual de un experto humano en un campo particular, pudiendo mejorar su productividad, ahorrar tiempo y dinero, conservar sus valiosos conocimientos y difundirlos más fácilmente.

A la vez, el usuario puede aprender observando el comportamiento del sistema. Es decir, los sistemas expertos se pueden considerar simultáneamente como un medio de ejecución y transmisión del conocimiento. Lo que se intenta, de esta manera, es representar los mecanismos heurísticos que intervienen en un proceso de descubrimiento. Estos mecanismos forman ese conocimiento difícil de expresar que permite que los expertos humanos sean eficaces calculando lo menos posible. Los sistemas expertos contienen ese "saber hacer".

## 2.2 Historia de los sistemas expertos

A comienzos de los años 50 el conocido Alan Mathingsong Turing publicó "Inteligencia y Funcionamiento de las Máquinas" con el fin de demostrar hasta que punto estas tienen inteligencia. En estos años se dieron varias definiciones de lo que significaba la inteligencia en una máquina. Sobre lo que denominamos la inteligencia artificial. Definición de Elaim Reich:

La inteligencia artificial es el estudio de cómo hacer que los ordenadores hagan cosas que, en estos momentos, hace mejor el hombre.

Definición de Alexander Sport (1971):

En su obra "Sporls-Computerbuch": Bajo Inteligencia entiendo la capacidad de un ser vivo o una máquina de ordenar informaciones, extensas observaciones,

experiencias, descubrir interrelaciones para abstraer de esta forma cosas y poderlas ligar entre sí.

Uno de los primeros sistemas expertos se llamo Dendral y era capaz de calcular o descubrir hechos relativos a la estructura molecular a partir de unos datos químicos sin elaborar.

Otros sistemas expertos famosos son MYCIN que diagnostica enfermedades de la sangre y que sugiere un tratamiento y PUFF, un sistema similar pero para enfermedades de pulmón. En el año 1950 el campo de la automática recibe un gran impulso cuando Wiener desarrolla el principio de la retroalimentación. La teoría de la retroalimentación es base fundamental de los sistemas de control.

En **1955** Newell y Simon desarrollan la Teoría de la lógica. Este desarrollo permitió desarrollar un programa que exploraba la solución a un problema utilizando ramas y nudos, seleccionando únicamente las ramas que más parecían acercarse a la solución correcta del problema.

En **1956**, se celebra una conferencia en Vermont (USA) de gran trascendencia en el desarrollo de la IA. John McCarthy propone por primera vez el uso del término "Inteligencia Artificial" para denominar el estudio del tema.

En **1957**, aparece la primera versión de "The General Problem Solver" (GPS, Solucionador general de problemas), un programa capaz de solucionar problemas de sentido común pero no problemas del mundo real como diagnósticos médicos. El GPS utilizaba la teoría de la retroalimentación de Wiener.

En **1958** McCarthy anuncia su nuevo desarrollo en el lenguaje LISP, lista de procesamiento (List Processing), el lenguaje de elección para todos aquellos desarrolladores inmersos en el estudio de la IA.

En **1963**, el Instituto Tecnológico de Massachusetts (MIT) recibe una subvención de 2,2 millones de dólares del gobierno de los Estados Unidos en concepto de investigación en el campo de la IA. De esa forma, se comprueba la importancia que el Gobierno concede a la investigación dentro de ese campo. En 1965 aparece DENDRAL, el primer sistema experto. Es en ese año cuando Feigenbaum entra a formar parte del departamento de informática de Stanford. Allí conoció a Joshua Lederberg, el cual quería averiguar cual era la estructura de las moléculas

orgánicas completas. El objetivo de DENDRAL fue estudiar un compuesto químico. El descubrimiento de la estructura global de un compuesto exigía buscar en un árbol las posibilidades, y por esta razón su nombre es DENDRAL que significa en griego "árbol".

Antes de DENDRAL los químicos solo tenían una forma de resolver el problema, estar era tomar unas hipótesis relevantes como soluciones posibles, y someterlas a prueba comparándolas con los datos. La realización de DENDRAL duró más de diez años (1965-1975).

En **1965** también se empezaron a utilizar técnicas para la resolución de problemas que se caracterizaban por la búsqueda heurística como modelo para la resolución de problemas, y con ellas comenzó la investigación y desarrollo de los sistemas expertos.

En **1972**, en la Universidad de Stanford se desarrolla MYCIN, sistema experto dentro del campo de la medicina para diagnóstico de enfermedades infecciosas en la sangre. MYCIN se trataba de un sistema experto para el diagnóstico de enfermedades infecciosas. Desde los resultados de análisis de sangre, cultivos bacterianos y demás datos, el programa era capaz de determinar, o en lo menos, sugerir el microorganismo que estaba causando la infección. Después de llegar a una conclusión, MYCIN prescribía una medicación que se adaptaba perfectamente a las características de la persona, tales como el peso corporal de este.

En **1972** aparece el lenguaje PROLOG basado en las teorías de Minsky. En **1973** se desarrolla el sistema experto llamado TIERESIAS. El cometido de este sistema experto era el de servir de intérprete entre MYCIN y los especialistas que lo manejaban, a la hora introducir nuevos conocimientos en su base de datos. El especialista debía utilizar MYCIN de una forma normal, y cuando este cometiera un error en un diagnóstico (hecho producido por la falta o fallo de información en el árbol de desarrollo de teorías) TEIRESIAS corregiría dicho fallo destruyendo la regla si es falsa o ampliándola si es eso lo que se necesita.

En **1979** aparece XCON, primer programa que sale del laboratorio. Su usuario fue la corporación de equipamientos digital (Digital Equipment Corporation, DEC).El



cometido de XCON sería configurar todos los ordenadores que saliesen de la DEC.

En abril de **1979** el equipo de investigación que lo había diseñado pensó que ya estaba preparado para salir, y fue entonces, cuando se hizo una prueba real, esperando resolver positivamente un 95% de las configuraciones, este porcentaje tal alto se quedó en un 20% al ser contrastado con la realidad; XCON volvió al laboratorio, donde fue revisado y a finales de ese mismo año funcionó con resultados positivos en la DEC.

En **1980** se instauró totalmente en DEC. Y en 1984, el XCOM había crecido hasta multiplicarse por diez. El XCOM supuso un ahorro de cuarenta millones de dólares al año para la DEC.

Entre los años 80 a 85 se produce la revolución de los Sistemas Expertos. En estos 5 años se crearon diversos sistemas expertos como el DELTA, de la General Electric Company, para la reparación de locomotoras diesel y eléctricas. "Aldo en Disco" para la reparación de calderas hidrostáticas giratorias usadas para la eliminación de bacterias. Se crearon multitud de empresas dedicadas a los sistemas expertos como Teknowledge Inc., Carnegie Group, Symbolics, Lisp Machines Inc., Thinking Machines Corporation, Cognitive Systems Inc. formando una inversión total de 300 millones de dólares. Los productos más importantes que creaban estas nuevas compañías eran las "máquinas Lisp", que se trataba de unos ordenadores que ejecutaban programas LISP con la misma rapidez que en un ordenador central, y el otro producto fueron las "herramientas de desarrollo de sistemas expertos".

En 1987 XCON empieza a no ser rentable. Los técnicos de DEC tuvieron que actualizar XCOM rápidamente llegando a gastar más de dos millones de dólares al año para mantenimiento y algo parecido ocurrió con el DELTA. También en **1987** aparecieron los microordenadores Apple y compatibles IBM con una potencia parecida a los LISP. El software se transfirió a máquinas convencionales utilizando el lenguaje "C" lo que acabó con el LISP.

A partir de **1990** y con el desarrollo de la informática, se produce un amplio desarrollo en el campo de la IA y los sistemas expertos, pudiéndose afirmar que

estos se han convertido en una herramienta habitual en determinadas empresas en la actualidad.

La evolución histórica de los métodos utilizados en el desarrollo de los sistemas expertos también se ha producido a medida que se ha ido desarrollando la IA y los diferentes métodos que se han empleado para su resolución. El desarrollo de lenguajes como LISP y PROLOG condicionó esa evolución, así como investigaciones en diversos campos relacionados.

**Los primeros sistemas expertos que se desarrollaron en los años 60 eran capaces de resolver solo problemas basados en situaciones determinadas, mediante sistemas de reglas .Es a partir de los 70 cuando se empiezan a resolver problemas basados en situaciones inciertas, basados en medidas difusas (sistema experto Difuso), al principio y en redes probabilísticas con posterioridad (redes neuronales).**

### **2.3. Definición y características de un sistema experto**

Un sistema experto es un sistema elaborado con técnicas de IA que, de igual forma que el experto humano al que intenta emular, resuelve los problemas complejos y difíciles que se circunscriben a un dominio específico y delimitado.

La finalidad principal de los sistemas expertos es la correcta reproducción del comportamiento de un experto humano en su dominio de competencia.

### **2.4. Los sistemas expertos**

Suponen uno de los ejemplos más claros de la evolución de la IA y de su éxito cuando ésta ha prescindido de los objetivos exageradamente ambiciosos de los primeros años, y tiene que delimitar el dominio y las características de los problemas que se tienen que resolver. © FUOC • P01/79008/00057 25 Inteligencia artificial .El sistema experto utiliza procesos que imitan el razonamiento humano (deducción, inducción, estrategias de búsqueda de soluciones, etc.) en el momento de resolver los problemas. Y todo esto lo consigue utilizando los conocimientos de base, suministrados en origen por un experto humano, a los que

incorpora los conocimientos que el sistema experto informático “aprende” durante su actividad como “experto”.

Además, el sistema experto tiene que ser capaz de justificar las decisiones y los resultados obtenidos y atribuirles grados de credibilidad. También, como hacen a veces los expertos humanos, debe ser capaz de razonar a partir de datos inciertos.

## **2.5. Estructura básica de un sistema experto**

En la figura 3 se muestra la estructura básica de un sistema experto en el que se percibe claramente un aspecto fundamental: la separación de los datos que forman el conocimiento, de las estrategias de resolución o procedimiento con los que se elaboran las soluciones.

Los conocimientos se almacenan en la **base de conocimientos** y en la **base de hechos**, y los procedimientos capaces de razonar se implementan en el **motor de inferencia**.

El esquema también muestra la necesidad de **interfaces** que permitan el acceso al sistema, tanto del experto humano que alimenta la base de conocimientos como del usuario del sistema experto que proporciona los hechos que determinan una utilización concreta del sistema experto. El usuario también obtiene las respuestas que proporciona el sistema.



El esquema también muestra la necesidad de **interfaces** que permitan el acceso al sistema, tanto del experto humano que alimenta la base de conocimientos como del usuario del sistema experto que proporciona los hechos que determinan una utilización concreta del sistema experto. El usuario también obtiene las respuestas que proporciona el sistema.

## **2.6. Principios del sistema experto**

Los sistemas expertos forman parte de un firme y verdadero avance en inteligencia artificial. Los sistemas expertos pueden incorporar miles de reglas. Para una persona sería una experiencia casi "traumática" el realizar una búsqueda de reglas posibles al completado de un problema y concordar estas con las posibles consecuencias, mientras que se sigue en un papel los trazos de un árbol de búsqueda. Los sistemas expertos realizan amablemente esta tarea; mientras que la persona responde a las preguntas formuladas por el sistema experto, este busca recorriendo las ramas más interesantes del árbol, hasta dar con la respuesta al problema, o en su falta, la más parecida a esta. Los sistemas expertos tienen la ventaja frente a otros tipos de programas de Inteligencia Artificial, de proporcionar gran flexibilidad a la hora de incorporar nuevos conocimientos. Para ello solo tenemos que introducir la nueva regla que

deseemos hacer constar, sin necesidad de cambiar el funcionamiento propio del programa.

Los sistemas expertos son "auto explicativos", al contrario que los programas convencionales, en los que el conocimiento como tal está encriptado junto al propio programa en forma de lenguaje de ordenador. Los expertos de IA dicen que los sistemas expertos tienen conocimiento declarativo, mientras que en los demás programas es procedural.

Para realizar un sistema experto se necesitan al menos dos personas el Experto del Dominio (profesional X) y un Ingeniero de Conocimiento (programador), que estos van enlazar sus experiencias almacenándolos en la Base de conocimientos que mediante la interface va a permitir al usuario llegara comunicarse con el motor de inferencia, el cual va a tomar la decisión de aplicar todo lo almacenado en la base de conocimientos.

La Base de conocimiento nos halla la base datos y esta está compuesta por lenguajes de predicado, este es uno de los componentes que contiene el conocimiento del experto o también llamado base de datos, su función es almacenar experiencias, conocimientos, etc. de una determinada área.

Existen dos tipos de base de conocimiento:

### **El procedural**

Se usa en los lenguajes estructurados, como son Pascal, C, Visual Basic etc.

### **El declarativo**

Está basado en hechos que vienen a ser acciones que se dan dentro del problema se utilizan los lenguajes Prolog y Lisp.

## **2.7. Arquitectura y funcionamiento de los sistemas expertos**

No existe una estructura de sistema experto común. Sin embargo, la mayoría de los sistemas expertos tienen unos componentes básicos: base de conocimientos, motor de inferencia, base de datos e interfaz con el usuario. Muchos tienen, además, un módulo de explicación y un módulo de adquisición del conocimiento.

La base de conocimientos contiene el conocimiento especializado extraído del experto en el dominio. Es decir, contiene conocimiento general sobre el dominio en el que se trabaja. El método más común para representar el conocimiento es

mediante reglas de producción. El dominio de conocimiento representado se divide en pequeñas fracciones de conocimiento o reglas SI... ENTONCES (If...Then). Cada regla constará de una parte denominada condición y de una parte denominada acción, y tendrá la forma:

SI condición ENTONCES acción. Como ejemplo se puede considerar la siguiente regla médica:

SI el termómetro marca 39° Y el termómetro funciona correctamente ENTONCES el paciente tiene fiebre.

Una característica muy importante es que la base de conocimientos es independiente del mecanismo de inferencia que se utiliza para resolver los problemas. De esta forma, cuando los conocimientos almacenados se han quedado obsoletos, o cuando se dispone de nuevos conocimientos, es relativamente fácil añadir reglas nuevas, eliminar las antiguas o corregir errores en las existentes. No es necesario reprogramar todo el sistema experto. Las reglas suelen almacenarse en alguna secuencia jerárquica lógica, pero esto no es estrictamente necesario. Se pueden tener en cualquier secuencia y el motor de inferencia las usará en el orden adecuado que necesite para resolver un problema. Una base de conocimientos muy ingenua, para identificar vehículos, podría ser la siguiente:

**Regla 1:** SI tiene 2 ruedas Y utiliza moto ENTONCES es una motocicleta.

**Regla 2:** SI tiene 2 ruedas Y es movido por el hombre ENTONCES es una bicicleta.

**Regla 3:** SI tiene 4 ruedas Y utiliza motor Y pesa menos de 3500 Kg ENTONCES es un coche.

Existen reglas de producción que no pertenecen al dominio del problema. Estas reglas se llaman meta reglas (reglas sobre otras reglas) y su función es indicar bajo qué condiciones deben considerarse unas reglas en vez de otras. Un ejemplo de meta regla es:

SI hay reglas que usan materias baratas Y hay reglas que usan materias caras ENTONCES usar antes las primeras que las segundas.

## **2.8. Arquitectura básica de los sistemas expertos**

**Base de conocimientos:** Es la parte del sistema experto que contiene el conocimiento sobre el dominio. Hay que obtener el conocimiento del experto y codificarlo en la base de conocimientos. Una forma clásica de representar el conocimiento en un sistema experto son las reglas. Una regla es una estructura condicional que relaciona lógicamente la información contenida en la parte del antecedente con otra información contenida en la parte del consecuente.

**Base de hechos** (Base de datos): es una parte de la memoria del ordenador que se utiliza para almacenar los datos recibidos inicialmente para la resolución de un problema. Contiene conocimiento sobre el caso concreto en que se trabaja. También se registrarán en ella las conclusiones intermedias y los datos generados en el proceso de inferencia. Al memorizar todos los resultados intermedios, conserva el vestigio de los razonamientos efectuados; por lo tanto, se puede utilizar explicar las deducciones y el comportamiento del sistema.

**Motor de inferencia:** El sistema experto modela el proceso de razonamiento humano con un módulo conocido como el motor de inferencia. Dicho motor de inferencia trabaja con la información contenida en la base de conocimientos y la base de hechos para deducir nuevos hechos. Contrasta los hechos particulares de la base de hechos con el conocimiento contenido en la base de conocimientos para obtener conclusiones acerca del problema.

**Subsistema de explicación:** Una característica de los sistemas expertos es su habilidad para explicar su razonamiento. Usando el módulo del subsistema de explicación, un sistema experto puede proporcionar una explicación al usuario de por qué está haciendo una pregunta y cómo ha llegado a una conclusión. Este módulo proporciona beneficios tanto al diseñador del sistema como al usuario. El diseñador puede usarlo para detectar errores y el usuario se beneficia de la transparencia del sistema.




Figura 2.1 Esquema del diseño de un sistema experto.

**Interfaz de usuario:** La interacción entre un sistema experto y un usuario se realiza en lenguaje natural. También es altamente interactiva y sigue el patrón de la conversación entre seres humanos. Para conducir este proceso de manera aceptable para el usuario es especialmente importante el diseño del interfaz de usuario. Un requerimiento básico del interfaz es la habilidad de hacer preguntas. Para obtener información fiable del usuario hay que poner especial cuidado en el diseño de las cuestiones. Esto puede requerir diseñar el interfaz usando menús o gráficos interacción.

## 2.9. Resumen del funcionamiento de un SE.

El motor de inferencias: es un programa que controla el proceso de razonamiento que seguirá el sistema experto. Utilizando los datos que se le suministran, recorre la base de conocimientos para alcanzar una solución. La estrategia de control puede ser de encadenamiento progresivo o de encadenamiento regresivo. En el primer caso se comienza con los hechos disponibles en la base de datos, y se buscan reglas que satisfagan esos datos, es decir, reglas que verifiquen la parte SI. Normalmente, el sistema sigue los siguientes pasos:



1. Evaluar las condiciones de todas las reglas respecto a la base de datos, identificando el conjunto de reglas que se pueden aplicar (aquellas que satisfacen su parte condición).
2. Si no se puede aplicar ninguna regla, se termina sin éxito; en caso contrario se elige cualquiera de las reglas aplicables y se ejecuta su parte acción (esto último genera nuevos hechos que se añaden a la base de datos).
3. Si se llega al objetivo, se ha resuelto el problema; en caso contrario, se vuelve al paso 1.

A este enfoque se le llama también guiado por datos, porque es el estado de la base de datos el que identifica las reglas que se pueden aplicar. Cuando se utiliza este método, el usuario comenzará introduciendo datos del problema en la base de datos del sistema. Al encadenamiento regresivo se le suele llamar guiado por objetivos, ya que, el sistema comenzará por el objetivo (parte acción de las reglas) y operará retrocediendo para ver cómo se deduce ese objetivo partiendo de los datos. Esto se produce directamente o a través de conclusiones intermedias o subobjetivos. Lo que se intenta es probar una hipótesis a partir de los hechos contenidos en la base de datos y de los obtenidos en el proceso de inferencia.

En la mayoría de los sistemas expertos se utiliza el encadenamiento regresivo. Este enfoque tiene la ventaja de que el sistema va a considerar únicamente las reglas que interesan al problema en cuestión. El usuario comenzará declarando una expresión E y el objetivo del sistema será establecer la verdad de esa expresión.

Para ello se pueden seguir los siguientes pasos:

1. Obtener las reglas relevantes, buscando la expresión E en la parte acción (éstas serán las que puedan establecer la verdad de E).
2. Si no se encuentran reglas para aplicar, entonces no se tienen datos suficientes para resolver el problema; se termina sin éxito o se pide al usuario más datos.

3. Si hay reglas para aplicar, se elige una y se verifica su parte condición C con respecto a la base de datos.
4. Si C es verdadera en la base de datos, se establece la veracidad de la expresión E y se resuelve el problema.
5. Si C es falsa, se descarta la regla en curso y se selecciona otra regla.
6. Si C es desconocida en la base de datos (es decir, no es verdadera ni falsa), se le considera como sub.-objetivo y se vuelve al paso 1 (C será ahora la expresión E).

Existen también enfoques mixtos en los que se combinan los métodos guiados por datos con los guiados por objetivos. El interfaz de usuario permite que el usuario pueda describir el problema al sistema experto. Interpreta sus preguntas, los comandos y la información ofrecida. A la inversa, formula la información generada por el sistema incluyendo respuestas a las preguntas, explicaciones y justificaciones. Es decir, posibilita que la respuesta proporcionada por el sistema sea inteligible para el interesado. También puede solicitar más información si le es necesaria al sistema experto. En algunos sistemas se utilizan técnicas de tratamiento del lenguaje natural para mejorar la comunicación entre el usuario y el sistema experto.

La mayoría de los sistemas expertos contienen un módulo de explicación, diseñado para aclarar al usuario la línea de razonamiento seguida en el proceso de inferencia. Si el usuario pregunta al sistema cómo ha alcanzado una conclusión, éste le presentará la secuencia completa de reglas usada. Esta posibilidad de explicación es especialmente valiosa cuando se tiene la necesidad de tomar decisiones importantes amparándose en el consejo del sistema experto. Además, de esta forma, y con el tiempo suficiente, los usuarios pueden convertirse en especialistas en la materia, al asimilar el proceso de razonamiento seguido por el sistema. El subsistema de explicación también puede usarse para depurar el sistema experto durante su desarrollo.

El módulo de adquisición del conocimiento permite que se puedan añadir, eliminar o modificar elementos de conocimiento (en la mayoría de los casos reglas) en el sistema experto. Si el entorno es dinámico es muy necesario, puesto que, el sistema funcionará correctamente sólo si se mantiene actualizado su conocimiento. El módulo de adquisición permite efectuar ese mantenimiento, anotando en la base de conocimientos los cambios que se producen.

## **2.10 Aplicaciones de los sistemas expertos**

Un sistema experto es muy eficaz cuando tiene que analizar una gran cantidad de información, interpretándola y proporcionando una recomendación a partir de la misma. UN ejemplo es el análisis financiero, donde se estudian las oportunidades de inversión, dependiendo de los datos financieros de un cliente y de sus propósitos.

Para detectar y reparar fallos en equipos electrónicos, se utilizan los sistemas expertos de diagnóstico y depuración, que formulan listas de preguntas con las que obtienen los datos necesarios para llegar a una conclusión. Entonces recomiendan las acciones adecuadas para corregir los problemas descubiertos. Este tipo de sistemas se utilizan también en medicina (ej. MYCIN y PUFF), y para localizar problemas en sistemas informáticos grandes y complejos.

Los sistemas expertos son buenos para predecir resultados futuros a partir del conocimiento que tienen. Los sistemas meteorológicos y de inversión en bolsa son ejemplos de utilización en este sentido.

La planificación es la secuencia de acciones necesaria para lograr una meta. Conseguir una buena planificación a largo plazo es muy difícil. Por ello, se usan sistemas expertos para gestionar proyectos de desarrollo, planes de producción de fábricas, estrategia militar y configuración de complejos sistemas informáticos, entre otros.

Cuando se necesita controlar un proceso tomando decisiones como respuesta a su estado y no existe una solución algorítmica adecuada, es necesario usar un sistema experto. Este campo comprende el supervisar fábricas automatizadas,

factorías químicas o centrales nucleares. Estos sistemas son extraordinariamente críticos porque normalmente tienen que trabajar a tiempo real.

El diseño requiere una enorme cantidad de conocimientos debido a que hay que tener en cuenta muchas especificaciones y restricciones. En este caso, el sistema experto ayuda al diseñador a completar el diseño de forma competente y dentro de los límites de costes y de tiempo. Se diseñan circuitos electrónicos, circuitos integrados, tarjetas de circuito impreso, estructuras arquitectónicas, coches, piezas mecánicas, etc. Por último, un sistema experto puede evaluar el nivel de conocimientos y comprensión de un estudiante, y ajustar el proceso de aprendizaje de acuerdo con sus necesidades.

## **2.11. Uso de los sistemas expertos según el tipo de problema.**

**Interpretación:** deducir situaciones a partir de datos observados Análisis de imágenes, reconocimiento del habla, inversiones financieras.

**Predicción:** Inferir posibles consecuencias a partir de una situación Predicción meteorológica, previsión del tráfico, evolución de la Bolsa Diagnóstico Deducir fallos a partir de sus efectos Diagnóstico médico, detección de fallos en electrónica

**Diseño:** configurar objetos bajo ciertas especificaciones Diseño de circuitos, automóviles, edificios, etc.

**Planificación:** desarrollar planes para llegar a unas metas Programación de proyectos e inversiones, planificación militar.

**Depuración:** prescribir remedios para funcionamientos erróneos Desarrollo de software y circuitos electrónicos.

**Reparación:** efectuar lo necesario para hacer una corrección Reparar sistemas informáticos, automóviles, etc.

**Instrucción:** diagnóstico, depuración y corrección de una conducta Corrección de errores, enseñanza.

**Control:** mantener un sistema por un camino previamente trazado. Interpreta, predice y supervisa su conducta Estrategia militar, control de tráfico aéreo.

### **2.11.1. Ventajas de los SE:**

El acceso al conocimiento y al juicio de un experto es extremadamente valioso en muchas ocasiones (prospecciones petrolíferas, manejo de valores bursátiles, diagnóstico de enfermedades, etc.), sin embargo, en la mayoría de los campos de actividad existen más problemas por resolver que expertos para resolverlos. Para solucionar este desequilibrio es necesario utilizar un sistema experto. En general, actuará como ayudante para los expertos humanos y como consultor cuando no se tiene otro acceso a la experiencia.

Un sistema experto, además, mejora la productividad al resolver y decidir los problemas más rápidamente. Esto permite ahorrar tiempo y dinero. A veces sin esa rapidez las soluciones obtenidas serían inútiles.

Los valiosos conocimientos de un especialista se guardan y se difunden, de forma que, no se pierden aunque desaparezca el especialista. En los sistemas expertos se guarda la esencia de los problemas que se intenta resolver y se programa cómo aplicar los conocimientos para su resolución. Ayudan a entender cómo se aplican los conocimientos para resolver un problema. Esto es útil porque normalmente el especialista da por ciertos sus conocimientos y no analiza cómo los aplica.

Se pueden utilizar personas no especializadas para resolver problemas. Además si una persona utiliza regularmente un sistema experto aprenderá de él, y se aproximará a la capacidad del especialista.

Con un sistema experto se obtienen soluciones más fiables gracias al tratamiento automático de los datos, y más contrastadas, debido a que se suele tener informatizado el conocimiento de varios expertos.

Debido a la separación entre la base de conocimiento y el mecanismo de inferencia, los sistemas expertos tienen gran flexibilidad, lo que se traduce en una mejor modularidad, modificabilidad y legibilidad del conocimiento.

Otra ventaja es que este tipo de sistemas pueden utilizar razonamiento aproximado para hacer deducciones y que pueden resolver problemas sin solución algorítmica.

### **2.11.2. Desventajas de los SE:**

Los sistemas expertos también tienen inconvenientes. El conocimiento humano es complejo de extraer y, a veces, es problemático representarlo. Si un problema sobrepasa la competencia de un sistema experto, sus prestaciones se degradan de forma notable. Además, las estrategias de razonamiento de los motores de inferencia suelen estar programadas procedimentalmente y se adaptan mal a las circunstancias. Están limitados para tratar problemas con información incompleta.

Un experto humano no estudia progresivamente una hipótesis, sino que decide de inmediato cuando se enfrenta a una situación análoga a otra ocurrida en el pasado. Los sistemas expertos no utilizan este razonamiento por analogía.

Los costes y duración del desarrollo de un sistema experto son bastante considerables (aunque se suelen amortizar rápidamente) y su campo de aplicación actual es restringido y específico. Finalmente, hay que tener en cuenta los problemas sociales que acarrearán al ser humano, susceptibles de influir en la estructura y número de empleos.

### **2.12 Conclusiones.**

- Los sistemas expertos ayudan al diagnóstico y supervisión de fallas o averías en los motores de inducción.
- El sistema experto que será elaborado en este estudio de la lógica difusa y redes neuronales.
- El sistema experto solo va a atender las principales averías en los motores de inducción.
- La implementación de un Sistema Experto que incluya los algoritmos mostrados en este capítulo puede ser construida a través del uso de las técnicas de Inteligencia artificial tales como la Lógica Difusa o las Redes Neuronales.

## Capítulo III Técnicas de inteligencia artificial.

### 3.1. Introducción

En este capítulo realizaremos una breve descripción sobre las Redes Neuronales Artificial (ANN) y sus fundamentos. Las redes neuronales son una rama de la Inteligencia Artificial. En ellas el conocimiento se incorpora **mediante el aprendizaje a partir de ejemplos**.

Esta forma de adquirir el conocimiento es una de sus características más destacables: no se programa de forma directa, como en los sistemas expertos, sino que se adquiere a partir de ejemplos, por ajuste de parámetros de las neuronas mediante un algoritmo de aprendizaje.

Es un tipo de software muy utilizado para **reconocimiento de patrones**, como caracteres escritos, de voz, etc. Una red neuronal se parece al cerebro en dos ideas básicas:

- La red necesita una cantidad de información para entrenarse
- Las conexiones entre las neuronas se usan para almacenar las informaciones.

El uso de las redes neuronales ofrece muchas propiedades y capacidades, como el aprendizaje adaptativo, auto organizativo, funcionamiento en paralelo en tiempo real y tolerancia de fallos por la codificación redundante de la información. Desde punto de vista de solucionar problemas, las redes neuronales son diferentes de los ordenadores convencionales que usan algoritmos secuenciales, mientras que las redes neuronales actúan como el cerebro humano, procesando la información en paralelo, y también pueden aprender y generalizar a casos nuevos que no estaban incluidos durante el proceso del diseño. Las redes neuronales pueden procesar las informaciones más rápido que los ordenadores convencionales.

### **3.2. Similitud entre el sistema nervioso de los animales y las redes neuronales artificiales.**

La base y fuente de inspiración de las redes neuronales artificiales es la célula del sistema nervioso de los animales, conocida como neurona, y es por tanto importante observar su fisiología para comprender como los investigadores en ingeniería y matemática tratan de imitar los mecanismos de almacenamiento y procesamiento de la información en el cerebro en una neurona biológica, ver figura 3.1.1, se puede distinguir cuatro partes fundamentales: el soma, el axón, las sinapsis y las dendritas.

El soma

El soma o núcleo de la célula es la parte central redonda donde se realizan casi todas las funciones lógicas de la neurona.

El axón

El axón es una fibra nerviosa conectada directamente con el soma y que sirve como canal de salida. El axón usualmente está muy ramificado para permitir su conexión a un gran número de neuronas. En estos sistemas biológicos las señales son secuencias de impulsos que se propagan por el axón sin atenuación.

Las dendritas

Las dendritas son las entradas de información a la neurona. Son un grupo de fibras muy ramificadas y de forma irregular que se conectan directamente al soma. Se calcula entre  $10^3$  y  $10^4$  el número de dendritas en una neurona, permitiendo que se conecte a un gran grupo de otras neuronas.

Las sinapsis

Sinapsis son contactos especializados entre los axones y las dendritas de diferentes neuronas. Estas sinapsis pueden cambiar la polaridad de los potenciales provenientes de otras neuronas y en estos casos se suele hablar de naturaleza excitadora o inhibidora según sea su función para la excitación o bloques de la neurona. Se considera que el almacenamiento de la información está concentrado en estas conexiones sinápticas. Se conoce que en el sistema nervioso de los seres humanos estas conexiones sinápticas son de naturaleza química muy compleja a diferencia de los insectos que tienen conexiones de transmisión eléctrica simples.



McCulloch y Pitts construyeron un modelo básico de neurona artificial, con una neurona muy Simple a base de un sumador y una función de activación. Las conexiones (sinapsis) de una neurona se consideran como se muestra en la figura 3.1.1. En ellas, las activaciones  $x_i$  con unas determinadas intensidades  $w_{ji}$  de otras neuronas son sumadas, y se permite que en la salida de la neurona (axón) se origine una actividad siempre que la suma  $w_{ji}x_i$  supere un valor umbral ( $\theta_j$ ).


La expresión matemática de esta neurona es

$$y_i = \varphi \left( \sum_{i=1}^n w_{ji} x_i + \theta_j \right) \quad 3.1.1$$


Donde  $w_{ji}$  son los pesos sinápticos que ponderan las entradas  $x_i$  y  $\theta_j$  es el umbral.  $\varphi$  es la función de activación de la neurona y  $n$  es número total de pesos sinápticos conectados a entrada de la neurona. En algunos libros incluyen el umbral dentro de las entradas y de pesos quedando expresada la salida de neurona como:

$$y_i = \varphi \left( \sum_{i=0}^n w_{ji} x_i \right) \quad 3.1.2$$

Con  $x_0 = \pm 1$ , y  $w_{j0} = \theta_j$ , dando una presentación más compacta. Como función de activación,  $\varphi$ , se pueden usar muchas funciones, pero las más usadas para los casos no lineales son las sigmoides. En la sección siguiente se explican las funciones de activación más utilizadas en redes neuronales.




**Figura 3.1.1.** Modelo de la neurona biológica



**Figura. 3.1.2.** Modelo de neurona artificial

### 3.3. ¿Cómo se trabaja con las redes neuronales?

El modelo siguiente describe el procedimiento para operar con redes neuronales. Originalmente la red neuronal no dispone de ningún tipo de conocimiento útil almacenado. Para que la red neuronal ejecute una tarea es preciso **entrenarla**, en terminología estadística diríamos que es necesario **estimar los parámetros**.




**Es un procedimiento estadístico.**

En realidad todo el procedimiento que vemos en el modelo es estadístico: primero se selecciona un conjunto de datos, o patrones de aprendizaje en jerga neuronal. Después se desarrolla la arquitectura neuronal, número de neuronas, tipo de red. Por decirlo con otras palabras, se selecciona el modelo y el número de variables dependientes e independientes. Se procede a la fase de aprendizaje o estimación del modelo y a continuación se validan los resultados.

### 3.3.1 Funcionamiento.

Una de las misiones en una red neuronal consiste en simular las propiedades observadas en los sistemas neuronales biológicos a través de modelos matemáticos recreados mediante mecanismos artificiales (como un circuito integrado, un ordenador o un conjunto de válvulas). El objetivo es conseguir que las máquinas den respuestas similares a las que es capaz de dar el cerebro que se caracterizan por su generalización y su robustez.



Modelo del diseño y programación de una RNA. Perceptrón con 2 entradas

Una red neuronal se compone de unidades llamadas neuronas. Cada neurona recibe una serie de entradas a través de interconexiones y emite una salida. Esta salida viene dada por tres funciones:

1. Una función de propagación (también conocida como función de excitación), que por lo general consiste en la sumatoria de cada entrada multiplicada por el peso de su interconexión (valor neto). Si el peso es positivo, la conexión se denomina *excitatoria*; si es negativo, se denomina *inhibitoria*.
2. Una función de activación, que modifica a la anterior. Puede no existir, siendo en este caso la salida la misma función de propagación
3. Una función de transferencia, que se aplica al valor devuelto por la función de activación. Se utiliza para acotar la salida de la neurona y generalmente viene dada por la interpretación que queramos darle a dichas salidas. Algunas de las más utilizadas son la sigmoide (para obtener valores en el intervalo  $[0,1]$ ) y la tangente hiperbólica (para obtener valores en el intervalo

[-1,1]). Se puede observar en el modelo del diseño y programación de una RNA.

Con un paradigma convencional de programación en ingeniería del software, el objetivo del programador es modelar matemáticamente (con distintos grados de formalismo) el problema en cuestión y posteriormente formular una solución (programa) mediante un algoritmo codificado que *tenga* una serie de propiedades que permitan resolver dicho problema. En contraposición, la aproximación basada en las RNA parte de un conjunto de datos de entrada suficientemente significativo y el objetivo es conseguir que la red *aprenda* automáticamente las propiedades deseadas. En este sentido, el diseño de la red tiene menos que ver con cuestiones como los flujos de datos y la detección de condiciones, y más que ver con cuestiones tales como la selección del modelo de red, la de las variables a incorporar y el preprocesamiento de la información que formará el *conjunto de entrenamiento*. Asimismo, el proceso por el que los parámetros de la red se adecuan a la resolución de cada problema no se denomina genéricamente programación sino que se suele denominar *entrenamiento*.

Por ejemplo en una red que se va a aplicar al diagnóstico de imágenes médicas; durante la fase de entrenamiento el sistema recibe imágenes de tejidos que se sabe son cancerígenos y tejidos que se sabe son sanos, así como las respectivas clasificaciones de dichas imágenes. Si el entrenamiento es el adecuado, una vez concluido, el sistema podrá recibir imágenes de tejidos no clasificados y obtener su clasificación *sano/no sano* con un buen grado de seguridad. Las variables de entrada pueden ser desde los puntos individuales de cada imagen hasta un vector de características de las mismas que se puedan incorporar al sistema (por ejemplo, procedencia anatómica del tejido de la imagen o la edad del paciente al que se le extrajo la muestra).

### **3.3.2. Estructura.**

La mayoría de los científicos coinciden en que una RNA es muy diferente en términos de estructura de un cerebro animal. Al igual que el cerebro, una RNA se compone de un conjunto masivamente paralelo de unidades de proceso muy simples y es en las conexiones entre estas unidades donde reside la inteligencia de la red. Sin embargo, en términos de escala, un cerebro es muchísimo mayor que cualquier RNA creada hasta la actualidad, y las neuronas artificiales también son más simples que su contrapartida animal.

Biológicamente, un cerebro aprende mediante la reorganización de las conexiones sinápticas entre las neuronas que lo componen. De la misma manera, las RNA tienen un gran número de *procesadores* virtuales interconectados que de forma simplificada simulan la funcionalidad de las neuronas biológicas. En esta simulación, la reorganización de las conexiones sinápticas biológicas se modela mediante un mecanismo de *pesos*, que son ajustados durante la fase de aprendizaje. En una RNA entrenada, el conjunto de los pesos determina el *conocimiento* de esa RNA y tiene la propiedad de resolver el problema para el que la RNA ha sido entrenada.

Por otra parte, en una RNA, además de los pesos y las conexiones, cada neurona tiene asociada una función matemática denominada función de transferencia. Dicha función genera la señal de salida de la neurona a partir de las señales de entrada. La entrada de la función es la suma de todas las señales de entrada por el peso asociado a la conexión de entrada de la señal. Algunos ejemplos de entradas son la función escalón o Heaviside, la lineal o mixta, la sigmoideal y la función gaussiana, recordando que la función de transferencia es la relación entre la señal de salida y la entrada.

### 3.4. Función de activación.

En esta sección, se presenta las funciones las que más utilizations en estructuras de red neuronal artificial. Las funciones sigmoideas y lineales siempre usan en las redes neuronales con propagación hacia adelante.

#### a) Función escalón de conexión o desconexión.

Esta función define frecuentemente denominada escalón de dos posiciones (sí o no). La salida de esta función es, o bien una constante positiva, una constante negativa o cero. Esta función posee una discontinuidad en un punto que imposibilita la evaluación de la derivada en dicho punto. La figura 3.2.1 se representa la familia de estas funciones




Fig. 3.2.1: Función escalón de conexión y desconexión.

## b) Función saturación lineal.

Función saturación lineal es similar a la función de escalón de conexión o desconexión, salvo que en un rango determinado de la variable de entrada. La salida tiene un comportamiento proporcional. La figura 3.2.3 se muestra tan solo dos discontinuidades en su derivada.





Fig. 3.2.2: Función saturación lineal

### c) Función sigmoideal asimétrica

Es una función binaria, continua diferenciable en todo su dominio. La figura 3.2.3 expone una representación de esta función y es la función que se va a utilizar en el recorrido del trabajo.




**Fig.3.2.3:** Función sigmoideal asimétrica

$$\varphi = \frac{a}{1 + e^{-\gamma v}} + c \begin{cases} c = 0 \\ a = 1 \\ \gamma = 0:1 \end{cases}$$

### d) Función sigmoideal simétrica (tansig)

Esta función también denominada tangente hiperbólica es completamente diferenciable en todo su dominio, monótonamente creciente y posee una característica bipolar. La figura 3.2.4 se representa el gráfico de esta función. La función sigmoideal simétrica (tansig) es la que se utiliza en la construcción de la red neuronal artificial (RAN).



$$\varphi = \frac{a}{1 + e^{-\gamma v}} + c \begin{cases} c = -1 \\ a = 1 \\ \gamma = 0:1 \end{cases}$$

**Figura 3.2.4:** Función sigmoideal simétrica.



### **e) Función lineal (purelin).**

Esta función posee una característica tipo lineal como se observa en figura 3.2.5, la cual no tiene límites en su rango.




Figura 3.2.5. Función lineal.

## **3.5 Arquitectura de las redes neuronales artificiales.**

Si bien la red neuronal artificial (ANN) es la unidad principal, no menos importante es como se interconectan entre ellas para formar una red que procese la información. Nos referimos a la arquitectura como las diferentes formas de interconectar esas unidades básicas creando redes de topología diferentes. Pueden existir un sin número de posibles combinaciones de las conexiones entre ellas, sin embargo podemos definir algunas estructuras fundamentales.

### **3.5.1 Redes neuronales artificiales de propagación hacia adelante.**

Este tipo de estructura se organiza en un grupo de neuronas que procesan la información de entrada paralelamente y luego la salida de las neuronas pueden combinarse para obtener unas salidas de la red o alimentar otro grupo de neuronas. La figura 3.3.1.1 muestra la estructura de la red neuronal de una sola capa de salida. La figura 3.3.1.2 muestra una estructura de red neuronal multicapa (MFANN) que contiene una o más capas ocultas. La salida de cada neurona se conecta a las entradas de las neuronas de las siguientes capas hasta alcanzar a la capa de salida.




Fig. 3.3.1.1: Red de propagación de una capa




Fig. 3.3.1.2: Red de propagación multicapa

### 3.5.2 Red de Hopfield.

Algunas de las arquitecturas de redes neuronales se caracterizan por el hecho de que varias de sus entradas están realimentadas por salidas de la propia red neuronal. La red propuesta por Hopfield es un ejemplo de estas arquitecturas incluyendo su propio modelo de neurona, como se presenta en la sección anterior. La figura 3.3.2.1 muestra un esquema de una de las posibles combinaciones de redes Hopfield.




Fig. 3.3.2.1: Red neuronal de Hopfield

### 3.5.3 Red neuronal artificial de propagación con retardos de tiempo.

La red neuronal artificial con retardos de tiempo (TDANN) se plantea de forma básicamente similar a la red MFANN con sola diferencia de organizar los datos de entrada, es decir que cada entrada está multiplexada para ser una función de unidades del retardo del tiempo. Los algoritmos de entrenamiento y actualización son exactamente iguales sin embargo, en las entradas se añaden unos valores iguales a los retardos de tiempo de la entrada. La figura 3.3.3.1 ilustra una red neuronal artificial de propagación con retardos de tiempo.




Fig. 3.3.3.1: Red neuronal artificial de retardo de tiempo con tres unidades de retardo de tiempo en los nudos de la entrada

### 3.5.4 Red neurona artificial de respuesta de impulso finito.

La red neuronal artificial de impulso finito (FIRANN), mostrada con detalle en sección 3.6, es una forma compleja de la MFANN, en la cual cada entrada de cada

neurona depende de la salida actual y de los valores previos de las neuronas de la capa anterior. La figura 3.3.4.1 muestra la red FIRANN.




Fig3.3.4.1: Red neuronal artificial de respuesta de impulso finito FIRANN

### 3.6. Algoritmo de retropropagación. Consideraciones especiales.

El algoritmo de retropropagación garantiza la aplicación de pasos descendentes por la superficie en dimensional del error en función de los valores de los pesos de la red. Con el gradiente descendente, siempre que se realice un cambio en los pesos de la red, se asegura el descenso por la superficie del error hasta encontrar el valle más cercano, que puede corresponder a un mínimo local o al mínimo global. Una vez que la red se asienta en un mínimo cualquiera cesa el aprendizaje. En el desarrollo matemático del algoritmo no se asegura en ningún momento que el mínimo que se alcance sea global en lugar de uno local.

No tendría importancia que el aprendizaje se detuviera en un mínimo local o en algún punto estacionario de la superficie, con lo cual no se llegue a lograr el mínimo global de la función, si la solución es admisible desde el punto de vista del

error, es decir, si se llega a un error menor que un valor preestablecido para una aplicación dada. Un problema sería que el aprendizaje se detuviera en un mínimo local siendo el error aún demasiado alto. Afortunadamente, en la práctica, si una red deja de aprender antes de llegar a una solución adecuada, un cambio en el número de nodos ocultos o en los parámetros de aprendizaje suele resolver el problema, o bien puede volver a empezarse el entrenamiento con un conjunto diferente de pesos iniciales.

### 3.6.1 Control de la convergencia. Razón de aprendizaje.

En las técnicas de gradiente descendente, utilizadas en el algoritmo de retropropagación, es conveniente avanzar por la superficie del error con incrementos pequeños de los pesos, pues no se sabe lo lejos o lo cerca que se está de un punto mínimo. Esto puede lograrse con una selección adecuada de la razón de aprendizaje  $\eta$ . Si se utiliza un valor muy pequeño, serán muy pequeños también los cambios en los pesos y muy suave la trayectoria en el espacio de pesos, lo cual significa que la red tendrá que hacer un gran número de iteraciones. Si, por el contrario, el valor de  $\eta$  es elevado, los grandes cambios en los pesos provocarían que se avance muy rápido por la superficie del error con el riesgo de saltar el mínimo y estar oscilando alrededor de él, pero sin poder alcanzarlo, lo que haría inestable a la red.

El elegir un paso  $\eta$  adecuado influye en la velocidad con que converge el algoritmo. Normalmente su valor es un número pequeño del orden de 0.05 a 0.25 para asegurar que la red llegue a asentarse en una solución.

Es frecuente que se aumente el valor de  $\eta$  dentro del rango aceptado a medida que disminuye el error de la red durante la fase de aprendizaje. Así se acelera la convergencia.

4. una aplicación Hasta aquí hemos hablado de una razón de aprendizaje única para toda la red. Sin embargo, es frecuente oír hablar de una razón de aprendizaje  $\eta_{kp}$  dependiente de la conexión. En este caso muchas cosas interesantes podrían hacerse

5. Una función de activación, que modifica a la anterior. Puede no existir, siendo en este caso la salida la misma función de propagación.

Una función de transferencia, que se aplica al valor devuelto por la función de activación. Se utiliza para acotar la salida de la neurona y generalmente viene dada por la interpretación que queramos darle a dichas salidas. Algunas de las más utilizadas son la sigmoide (para obtener valores en el intervalo  $[0,1]$ ) y la tangente hiperbólica (para. Por ejemplo, en dada pueden definirse un conjunto de pesos fijos. Aquí, las señales de error son retropropagadas por la red de la manera usual, sólo que para esas conexiones  $\eta$  sería igual a cero.

### **3.6.2 Regla delta generalizada. Método del momento.**

Otra forma de aumentar la velocidad de convergencia de la red consiste en utilizar una técnica llamada momento. Consiste en añadir al valor de cambio de peso en el paso  $n$ , una fracción del cambio anterior, como se muestra en la siguiente expresión llamada regla delta generalizada:

$$\Delta W_{kp}(n) = \alpha \Delta W_{kp}(n-1) + \eta \delta_k(n) A_p(n)$$

donde  $\alpha$  que es el momento es usualmente un número positivo. Se puede demostrar matemáticamente que para que la red converja el valor del momento tiene que estar en el rango:  $0 \leq \alpha < 1$

De la expresión puede verse que:

- Cuando el ajuste de los pesos ( $\eta \delta_k(n) A_p(n)$ ) tiene el mismo signo que en el paso anterior, al aplicar la regla generalizada con momento el peso es ajustado en una cantidad mayor, es decir, la inclusión del momento en la expresión tiende a acelerar el proceso de aprendizaje. Como se comprende entonces, en este caso, el término momento puede también evitar que el proceso de aprendizaje se detenga en un mínimo local poco profundo de la superficie de error, pues se pasaría por él sin detectarlo.
- Cuando el ajuste de los pesos en dos pasos consecutivos tiene signos opuestos, el peso es ajustado en una menor cantidad. Por ello se dice que la

adición del momento tiene un efecto estabilizador cuando hay oscilación en el signo del gradiente descendente.

### **3.6.3 Dimensionamiento de la red. Número de neuronas ocultas.**

No se pueden dar reglas concretas para determinar el número de neuronas de una capa o el número de capas de la red. Igual ocurre a la hora de seleccionar el número de patrones de entrenamiento. Sólo se pueden dar algunas ideas generales deducidas de la experiencia de algunos autores.

El tamaño de la capa de entrada suele venir determinado por la naturaleza de la aplicación. Igual ocurre con la capa de salida. Respecto al número de capas de la red en general son suficientes 3 capas (entrada – oculta - salida) aunque hay veces que se necesitan más capas ocultas. Decidir cuantas neuronas debe tener la capa oculta (o capas ocultas) no es tan evidente. El número de neuronas ocultas interviene en la eficiencia del aprendizaje y de generalización de la red, pero no hay regla que indique el número óptimo para su selección. En cada problema se suele ensayar con distintos números de neuronas para organizar la representación interna y escoger el mejor. La idea más utilizada sobre todo en los sistemas simulados consiste en tener el menor número de neuronas ocultas posible, pues cada una de ellas supone una mayor carga para las unidades de procesamiento en el programa. En un sistema implementado en hardware no importa la carga de procesamiento pero sí habrá que tener en cuenta el problema de comunicación entre las distintas neuronas de la red.

Sobre la base de un entrenamiento a prueba y error es posible determinar el número final de neuronas ocultas en función de la eficiencia del sistema. Si la red converge sin problemas se pueden eliminar neuronas ocultas y si no converge es posible que haya que aumentar ese número. La topología general se puede basar, como se dijo, en el rendimiento global del sistema.

### **3.6.4 Datos de entrenamiento.**

Desdichadamente no hay una definición sencilla que sea aplicable a todos los casos, la experiencia suele ser la mejor maestra. A medida que uno va

adquiriendo soltura en la utilización de las RNA, se adquiere también un conocimiento acerca de cómo seleccionar y preparar los conjuntos de entrenamiento. Aquí se darán unas cuantas ideas generales.

Se pueden utilizar todos los datos que estén disponibles para entrenar la red aunque esto no es necesario ni recomendable. Es conveniente emplear un subconjunto de los datos para el entrenamiento y el resto para probar la red con el objeto de verificar que la misma puede llevar a cabo la asociación deseada al utilizar vectores de entrada que nunca haya visto durante el entrenamiento.

Si se está entrenando una red para que funcione en un entorno con ruido hay que incluir unos cuantos vectores de entrada con ruido en el conjunto de datos. Algunas veces esto ayuda en la convergencia, incluso en el caso en que no se espere ruido en las entradas.

La red de retro propagación admite bien la generalización. Es decir es capaz de adaptarse a las similitudes significativas de los vectores de entrada si pertenecen a una misma clase.

Si la red se entrena de modo inadecuado o insuficiente empleando un conjunto de vectores de entrada, la posterior identificación de miembros de esa clase puede ser imprecisa. Asegúrese bien entonces de que los datos de entrenamiento cubran todo el espacio de entradas esperado, pues la red no es capaz de extrapolar bien.

Durante el proceso de entrenamiento seleccione aleatoriamente los pares de vectores de entrada. En todo caso no entrene por completo a una red con vectores de una clase pasando después a otra clase pues la red se olvidará del entrenamiento original.

Si la función de salida es una sigmoide entonces será preciso aplicar una escala a los vectores de entrada. Deben utilizarse valores como 0.1 y 0.9 para representar los valores de entrada más pequeños y más grandes respectivamente.



### **3.6.5 Algunas sugerencias para hacer mejor el algoritmo de retropropagación del error.**

Con frecuencia se dice que el diseño de una red neuronal usando el algoritmo retropropagación (backpropagation) es más un arte que una ciencia debido a que en esto influye mucho la experiencia personal. A continuación se hará referencia a varios aspectos que ayudarán a un novato a lograr buenos resultados.

#### **I. Función de activación a utilizar.**

Siempre que sea posible debe utilizarse una función asimétrica, por ejemplo, la sigmoideal tangente hiperbólica:

$$\varphi(V_k) = a \tanh(b V_k)$$

Se ha demostrado que valores adecuados para las constantes son  $a = 1.716$  y  $b = 2/3$

#### **II. Selección de los valores de salida.**

Deben ser elegidos dentro del rango de la función de activación sigmoideal. Es decir, la respuesta deseada para la neurona  $k$  de la capa de salida debe ser una cantidad  $\varepsilon$  menor que la salida de la neurona (en valor absoluto), o sea:

$T_k = \text{salida máxima de } \varphi(.) - \varepsilon$  donde  $\varphi(.)$  es la función de activación usada en la neurona  $k$ .

De no cumplirse lo anterior el algoritmo de retropropagación tiende a llevar los parámetros libres a valores cada vez mayores.

#### **III. Inicialización de los parámetros libres de la red.**

Una buena inicialización de los parámetros libres de la red puede ayudar considerablemente a la convergencia del algoritmo. Lo ideal sería poder disponer de una información previa de los valores iniciales a poner, aunque esto es poco frecuente. En la práctica, por tanto, los pesos y vías deben recibir valores iniciales pequeños y aleatorios uniformemente distribuidos (por ejemplo, entre  $\pm 0.5$ ).

Puede demostrarse que si todos los pesos reciben el mismo valor inicial la red no podrá aprender nunca nada.

Una mala elección de los valores iniciales puede provocar el fenómeno conocido como saturación prematura, lo cual ocurre cuando la suma de los cuadrados de los errores (SSE) permanece casi constante por un período relativamente grande al inicio del proceso de entrenamiento.

Este fenómeno se produce cuando el nivel de actividad interno de las neuronas de la capa de salida tiene valor grande (por valores grandes de los pesos) y, como la función sigmoideal limita los valores de salida de la neurona entre 0 y +1 para la función logística (-1 y +1 para la tangente hiperbólica), las salidas de las neuronas en este caso casi no cambiarán y tampoco lo hará el error. Cuando esto ocurre el ajuste aplicado a los pesos de la neurona será muy pequeño (aún cuando el error asociado a la neurona sea grande) pues el valor del gradiente local de la neurona es casi cero. En esta situación se dice que la neurona está saturada.

Si la salida de la neurona está en un extremo (de la función logística) debiendo estar en el extremo contrario se dice que la neurona está incorrectamente saturada. Puede transcurrir gran tiempo de entrenamiento para que la red pueda salir de este estado.

En la capa de salida puede haber neuronas no saturadas y saturadas. Los pesos asociados a las primeras cambian rápidamente y si las neuronas saturadas al llegar a este punto continúan en este estado entonces se cae en el fenómeno de saturación prematura.

En 1991 Lee y otros demostraron mediante simulación, utilizando el modo de entrenamiento “batch”, que:

- Puede evitarse la saturación incorrecta eligiendo valores iniciales de los pesos sinápticos de la red uniformemente distribuidos en un rango pequeño de valores aunque si es demasiado pequeño el aprendizaje inicial puede ser muy lento.

- La saturación incorrecta es menos probable cuando el número de neuronas ocultas es bajo.
- La saturación incorrecta raramente ocurre cuando las neuronas de la red operan en su zona lineal.

Ruso (1991) recomendó usar la inicialización de los pesos neurona a neurona en el siguiente rango empírico de valores aleatorios de pesos y vías cuando se usa función de activación tangente hiperbólica:  $a \tan h(b V_k)$  siendo  $a = 1.716$  y  $b = 2/3$

$\left( -\frac{2.4}{F_i}, +\frac{2.4}{F_i} \right)$  Donde:  $F_i$  es el número total de entradas de la neurona “i” de la red.

Debe decirse por último que el fenómeno de la saturación prematura se diferencia del caer en un mínimo local en que una vez finalizado este período inicial el error continúa disminuyendo.

#### **IV. Todas las conexiones de la red deben tener ajustes similares.**

Típicamente las neuronas de las últimas capas tienden a tener valores mayores de su gradiente local, por lo cual el ajuste de los pesos de sus conexiones sería mayor si se utilizara el mismo valor de  $\eta$  para todas las neuronas de la red. Se recomienda entonces que el valor de la razón de aprendizaje de las últimas capas sea menor. Por otra parte, las neuronas con muchas entradas podrían tener también menor  $\eta$  que las que tengan menos entradas.

**V. Para la operación on line se recomienda el método de entrenamiento por patrón. Orden en el cual se presentan los patrones de entrenamiento.**

El orden en el cual se presentan los patrones de entrenamiento debe ser cambiado aleatoriamente para cada iteración, esto evita que la red memorice los ajustes de los pesos y mejora además la velocidad de convergencia. Un último aspecto a considerar es la posibilidad de convergencia hacia alguno de los mínimos locales que pueden existir en la superficie de error del espacio de pesos.

Debe decirse además que un pequeño error medio cuadrático no implica necesariamente una buena generalización, es decir, un buen comportamiento con datos que no haya visto antes.


**3.7. Factores que afectan el entrenamiento en las redes neuronales.**

El entrenamiento es un “proceso de acción complejo cuyo objetivo es influir de forma sistemática y orientada al objetivo, sobre el desarrollo de la persona. En este caso es un proceso que determina los pesos sinápticos óptimos que hacer que la evolución del error decrezca a un valor mínimo. Es decir que el entrenamiento de una red neuronal debe detenerse cuando el error se vuelve constante y no puede ser reducido, lo que significa que el proceso de entrenamiento ha alcanzado un mínimo local o global. Por tanto no podemos saber si el error está en mínimo local o en un mínimo global. El problema ahora es como saber si se trata de un mínimo local o global. Esta pregunta es muy difícil de responder. Una respuesta podría ser que mediante la prueba de generalización de la red neuronal y otra que mediante el entrenamiento de la red con diferentes grupos de condiciones iniciales y factores de aprendizaje hasta lograr un error mínimo.

**3.7.1 Los parámetros de función de activación sigmoidea.**

De acuerdo con expresión (3.4.5) de la función sigmoide, resulta evidente que los parámetros  $a$  y  $c$  se utiliza para elegir el tipo de función (sigmoide simétrica

o sigmoide asimétrica) y el parámetro  $\gamma$  se utiliza para cambiar la pendiente de la función como se muestra en las figuras 3.4.1.1 y 3.4.1.2. Estos parámetros tienen que seleccionarse cuidadosamente antes de iniciar el proceso del entrenamiento.




**Fig3.4.2:** Diagrama esquemático de la propagación hacia adelante y propagación hacia atrás


### 3.7.2 El factor de aprendizaje.

El aprendizaje es un cambio permanente de la conducta de la persona como resultado de la experiencia. Se refiere al cambio en la conducta o al potencial de la conducta de un sujeto en una situación dada, como producto de sus repetidas experiencias en dicha situación.

En expresión (3.4.10), resulta evidente que el factor del aprendizaje se utiliza para reducir el error de aprendizaje y además depende directamente del problema a solucionar. Si se deja el factor de aprendizaje constante, quizás el entrenamiento salte a un mínimo global o caiga en un mínimo local. Hay algoritmos para resolver estos problemas tales como el que reduce el factor de aprendizaje después cada iteración, multiplicándolo por un valor, adaptación del factor de aprendizaje y a base de la regla aprendizaje Delta-Bar-Delta, que se usa en este trabajo.



**Fig3.4.1.i:** Función sigmoidea asimétrica



**Fig3.4.1.2:** Función sigmoidea simétrica.

### 3.7.3 Regla de aprendizaje Delta-Bar-Delta

Con este método el factor de aprendizaje se introduce como una función del error de aprendizaje. La ecuación 3.4.10 se puede escribir como:

$$\nabla w_{ji}^{(l)}(n) = \eta_{ji}(n+1) \delta_j^{(l)}(n) y_i^{(l-1)}(n) \quad 3.5.3.1$$

donde  $\eta_{ji}(n+1)$  es el factor de aprendizaje actualizado. El nuevo factor de aprendizaje se define como:

$$\eta_{ji}(n+1) = \eta_{ji}(n) + \nabla \eta_{ji}(n+1) \quad 3.5.3.2$$

Donde

$$\nabla \eta_{ji}(n+1) = \begin{cases} k & \text{si } S_{ji}(n-1) D_{ji}(n) > 0 \\ -\beta \eta_{ji}(n) & \text{si } S_{ji}(n-1) D_{ji}(n) < 0 \\ & \text{o para otros casos} \end{cases} \quad 3.5.3.3$$

Y

$$D_{ji}(n) = -\sum_{b=1}^B \delta_j^{(b)}(n) y_i^{(b)}(n) \quad 3.5.3.4$$

Y

$$S_{ji}(n) = (1 - \xi) D_{ji}(n-1) + \xi S_{ji}(n-1) \quad 3.5.3.5$$

donde  $D_{ji}(n)$  es el valor actual de la derivada parcial de la superficie de error respecto del peso

$w_{ji}(n)$  y  $S_{ji}(n)$  es una suma ponderada exponencialmente de los valores de las derivadas actuales y anteriores de superficie del error respecto del peso  $w_{ji}(n)$  con  $\xi$  como base y el número de iteración como exponente.

La regla de aprendizaje “Delta-Bar-Delta” tiene otra ventaja, además de acelerar el proceso del aprendizaje y evitar los mínimos locales, reduce la influencia de la inicialización de los pesos.

### 3.7.4 El factor momento “momentum”.

Para hacer el proceso del entrenamiento mas rápido y para asegurarse de escapar de los mínimos locales sin incrementar el error después de haberlo

reducido, se pone el momentum en la ecuación 3.4.11 que se puede escribir como:

$$w_{ji}^{(l)}(n+1) = w_{ji}^{(l)}(n) + \nabla w_{ji}^{(l)}(n) + \alpha(w_{ji}^{(l)}(n) - w_{ji}^{(l)}(n-1)) \quad 3.5.4.1$$

donde  $\alpha$  es el factor momentum, que tiene un valor positivo menor que la unidad. El momentum también se puede actualizar usando la misma base mencionada en el algoritmo de actualización del factor de aprendizaje Delta --Bar --Delta.

### **3.7.5 Inicialización**

La inicialización es el primer proceso del entrenamiento de la red neuronal. Una buena selección de los valores iniciales de los pesos sinápticos y de los umbrales pueden ayudar enormemente en el diseño satisfactorio de la red y su entrenamiento. La inicialización de los pesos sinápticos y los umbrales deben distribuirse uniformemente en un rango pequeño para reducir la probabilidad de saturación de las neuronas en la red. Sin embargo, el rango no debe ser muy pequeño ya que puede originar que los gradientes del error sean inicialmente muy bajos, y el aprendizaje muy reducido.

### **3.7.6 Método de validación cruzada.**

Si se usan todos los patrones posibles en proceso del entrenamiento, no se puede decir que la red neuronal artificial generalizará. Por esto, usando el método de validación cruzada, se puede saber si la ANN puede generalizar o no y evitar sobre entrenamientos. Esto puede lograrse mediante una selección aleatoria de un 60% o 80% de los patrones disponibles como grupo de entrenamiento y el resto dejarlo para la prueba. Después de un cierto número de iteraciones, se detiene temporalmente el proceso de entrenamiento y se usa el grupo de prueba para ensayar la red neuronal. Repitiendo esto a lo largo de todo el proceso de entrenamiento se deberá reducir el error de prueba hasta un cierto instante, después del cual el error de prueba empezará a incrementarse de nuevo. El punto que corresponde con el mínimo error es el mejor ajuste de la red neuronal artificial.



### 3.8. Entrenamiento de las redes neuronales artificiales.

Para simplificar el entrenamiento, los umbrales o las polarizaciones se asumirán como unas entradas fijas a la neurona (1 o -1) a través de un peso sináptico adaptable. Por tanto, la red neuronal durante la operación de propagación hacia adelante puede explicarse tal como se muestra en la figura 3.4.1 usando un modelo de neurona mostrado en la figura 3.1.2.

La señal de error instantáneo a la salida de la neurona  $j$  en la iteración  $n$  de un ciclo de entrenamiento es:

$$e_j(n) = d_j(n) - y_j(n) \quad 3.4.1$$

donde :


$d_j$  = la salida deseada de la neurona  $j$ .

$y_j$  = la salida real de la neurona  $j$ .

Usando la suma instantánea de los errores cuadráticos  $E$  de la red:

$$E(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad 3.4.2$$

Donde  $C$  incluye todas las neuronas en la capa de salida de la red



**Fig. 3.4.1:** Proceso de propagación hacia adelante de una estructura de red

De las ecuaciones (3.1.1) a (3.4.2) resulta evidente que los valores de los pesos están incluidos en  $E(n)$ . Esto significa que los valores de los pesos deben ser seleccionados para minimizar el error de la salida total de la red. Esto puede

lograrse mediante las derivadas parciales del error  $E(n)$  respecto a cada peso sináptico, lo que da el gradiente instantáneo que finalmente lleva al cambio de los pesos sinápticos,  $\Delta w$ , y que minimiza el error de la salida al final del proceso de entrenamiento. La obtención de las formulas de entrenamiento se aparece más detallada en [38]. La figura 3.4.2 muestra un resumen del entrenamiento para un diagrama estructural de una MFANN durante el proceso de propagación y de retropropagación. El procedimiento de entrenamiento se resume como en los siguientes pasos:

1. Generar los datos de pares entrada y salida de la tabla para diferentes condiciones de operación.
2. Con la red inicialmente sin entrenar, es decir con los pesos seleccionados aleatoriamente, la señal de salida será totalmente diferente a la esperada para una entrada conocida.
3. Proceso de propagación hacia adelante: Se selecciona de la tabla una pareja de datos de entrada y salida  $[x(n), d(n)]$ . Para un patrón de entrada, se calcula la salida de la red y se compara con la salida deseada para obtener el error. Calcular las funciones de activación a través de los procesos de propagación hacia adelante capa tras capa. El nivel de actividad de la red,  $v$ , puede escribirse como

$$v_j^{(l)}(n) = \sum_{i=1}^p w_{ij}^{(l)}(n) y_i^{(l-1)}(n) \quad 3.4.3$$

Donde:

$v_j^{(l)}(n)$  = la actividad interna de la red de la neurona  $j$ , en la capa  $l$ , en la iteración  $n$ .

$y_i(n)$  = la salida de la  $i$ -ésima neurona en la capa  $l-1$  que conecta a la neurona  $j$  con la siguiente capa a través del peso sináptico  $w_{ij}$ .

$i$  = la neurona fuente.

$j$  = la neurona receptor.

La salida  $y$  de la neurona es:

$$y_j^{(l)}(n) = \varphi(v_j^{(l)}(n)) \quad 3.4.4$$

Donde  $\varphi$  es la función de activación.

Supuesto el uso de función asimétrica o simétrica sigmoidea, la señal de la salida de la neurona  $j$  en la capa  $l$  es:

$$y_j^{(l)} = \frac{a}{1 + e^{-\gamma \cdot v_j^{(l)}(n)}} + c \quad 3.4.5$$

Donde  $a$ ,  $c$  y  $\gamma$  son parámetros. Estos parámetros afectan directamente al problema que se va resolver. Haciendo  $c=-1$  y  $a=2$  se obtiene la función sigmoide simétrico (tangente hiperbólica), mientras  $c=0$  y  $a=1$  se tendrá la función sigmoide asimétrica. Estos parámetros deben seleccionarse cuidadosamente antes de iniciar el proceso del entrenamiento.

Si la neurona  $j$  está en la primera capa oculta ( $l=1$ ), se hace:

$$y_j^{(0)}(n) = x_j(n) \quad 3.4.6$$

Sin embargo, si la neurona  $j$  es en la capa de la salida ( $l=L$ ), se hace

$$y_j^{(L)}(n) = o_j(n) \quad 3.4.7$$

El error en la salida de la  $j$ -ésima neurona se obtiene aplicando la ecuación 3.4.1.

**4. Proceso de retropropagación:** Cabe señalar que el algoritmo que indica como minimizar la función del error es conocido como "Algoritmo de Retropropagación".

Los errores de la salida y en las capas oculta de la red se usan para calcular el gradiente local en la capa de salida  $l$ . Este gradiente es retropropagado hacia los nudos de entrada capa a capa, como ha mostrado en la figura 2.4.2, aplicando las siguientes ecuaciones:

para la neurona  $j$  en la capa de la salida  $L$

$$\delta_j^{(L)}(n) = e_j^{(L)}(n) o_j(n) (1 - o_j(n)) \quad 3.4.8$$

para la neurona  $j$  en la capa oculta  $l$

$$\delta_j^{(l)}(n) = y_j^{(l)}(n) (1 - y_j^{(l)}(n)) \sum_k \delta_k^{(l+1)}(n) w_{kj}^{(l+1)}(n) \quad 3.4.9$$

donde  $w_{jk}$  es el peso sináptico que conecta la neurona  $j$  en la capa  $l$  a la neurona  $k$  en la capa  $l+1$ .

Usando el gradiente local calculado por cada capa, el incremento de un peso sináptico puede calcularse como:

$$\nabla w_{ji}^{(l)}(n) = \eta \delta_j^{(l)}(n) y_i^{(l-1)}(n) \quad 3.4.10$$

donde  $\eta$  es factor de aprendizaje, que un valor positivo menor que la unidad. Sumando cada cambio en el peso a su correspondiente valor usado en etapa de propagación se obtendrá en nuevo valor del peso:

$$w_{ji}^{(l)}(n+1) = w_{ji}^{(l)} + \nabla w_{ji}^{(l)}(n) \quad 3.4.11$$

Con el error se calculan y ajustan los pesos de la red usando el algoritmo de retropropagación de tal forma que el nuevo error sea menor.

5. Se repite el paso anterior con cada conjunto de datos de entrada y salida hasta que el error para todo el conjunto del entrenamiento converja por debajo de un valor fijado.

Después del entrenamiento se prueba el comportamiento de la red neuronal fuera del control con un grupo arbitrario de entradas para asegurarse que el entrenamiento fue exitoso.

### **3.9. Implementación de las redes neuronales.**

Las redes neuronales durante la operación normal de propagación hacia adelante usan sólo dos operaciones matemáticas, la suma y la multiplicación, y las funciones sigmoideas y/o lineal. Cada neurona puede tener sus propios parámetros de la función sigmoidea. En este trabajo, las redes neuronales se entrenaron teniendo en cuenta que las neuronas en cada capa deben tener las mismas parámetros para facilitar la implementación de la misma. La implementación de las redes neuronales se hacen de diferentes maneras:

- a) Mediante un chip de red neuronal analógica entrenada electrónicamente “ETANN” (Electronically Trainable Analog Neural Network)[39]. El sistema de entrenamiento de red neuronal montado en un Intel (The Intel’s Neural Network

Training System) “iNNTS” se empleó para configurar la red neuronal “rala” para la generación de los ángulos de conmutación primarios][40].

b) Mediante una tarjeta DSP (“Digital Signal Processing”) grabando la función sigmoide en una EPROM. Este tipo tiene como aspecto negativo el elevado tiempo de respuesta de la red, especialmente sí se trata de una red grande. Para solucionar este problema, se puede implementar la red neuronal usando una tarjeta DSP por cada capa, especialmente cuando cada capa tiene su propia función de activación.

c) Usando tarjetas de redes neuronales que usan neuroprocesadores como la SAND y la SIOP[41]. En la tarjeta SAND una capa oculta puede tener hasta 512 neuronas y la función de activación hay que almacenarla en una EPROM y tiene que ser la misma para toda la red. La tarjeta SAND está diseñada para implementar las redes neuronales MFANN, RBF y Kohonen. En la tarjeta SIOP su capacidad esta limitada a la función sigmoidea esta implementada en la misma tarjeta y es la misma para toda la red. La tarjeta SIOP tiene un tiempo total de propagación de 2,52  $\mu$ s y con ella se pueden implementarlas redes MFANN y las redes recurrentes.

d) Usando matrices de microprocesadores de 16 bits. En este caso el tiempo de propagación se puede disminuir mucho poniendo un microprocesador por cada neurona y poniendo una EPROM que tenga la tabla de la función sigmoidea para cada microprocesador y otra para las matrices de los pesos. Esta configuración tiene la ventaja de ser de respuesta muy rápida y de cumplirse la idea básica de las redes neuronales, el procesamiento en paralelo de la señal. Otra configuración de este tipo de implementación es poner una matriz de una sola columna de microprocesadores cuyo número sea igual al mayor número de neuronas en cualquier capa y en cada caso del proceso de propagación, esta columna emule una capa concreta de la red neuronal.

e) Usando la tarjeta dSPACE [42]. Esta tarjeta o bien el conjunto “KIT” tiene la ventaja que dispone de un DSP de funcionamiento muy rápido (333 MHz). Esta

tarjeta funciona con Simulink y caja de herramientas (Toolbox) de redes neuronales de Matlab.

### **3.10. Ventajas.**

Las redes neuronales artificiales (RNA) tienen muchas ventajas debido a que están basadas en la estructura del sistema nervioso, principalmente el cerebro.

- **Aprendizaje:** Las RNA tienen la habilidad de aprender mediante una etapa que se llama *etapa de aprendizaje*. Esta consiste en proporcionar a la RNA datos como entrada a su vez que se le indica cuál es la salida (respuesta) esperada.
- **Auto organización:** Una RNA crea su propia representación de la información en su interior, descargando al usuario de esto.
- **Tolerancia a fallos:** Debido a que una RNA almacena la información de forma redundante, ésta puede seguir respondiendo aceptablemente aún si se daña parcialmente.
- **Flexibilidad:** Una RNA puede manejar cambios no importantes en la información de entrada, como señales con ruido u otros cambios en la entrada (ej. si la información de entrada es la imagen de un objeto, la respuesta correspondiente no sufre cambios si la imagen cambia un poco su brillo o el objeto cambia ligeramente)
- **Tiempo real:** La estructura de una RNA es paralela, por lo cuál si esto es implementado con computadoras o en dispositivos electrónicos especiales, se pueden obtener respuestas en tiempo real.

### **3.11. Aplicaciones.**

Las características de las RNA las hacen bastante apropiadas para aplicaciones en las que no se dispone a priori de un modelo identificable que pueda ser programado, pero se dispone de un conjunto básico de ejemplos de entrada (previamente clasificados o no). Asimismo, son altamente robustas tanto al ruido como a la disfunción de elementos concretos y son fácilmente paralelizables.

Esto incluye problemas de clasificación y reconocimiento de patrones de voz, imágenes, señales, etc. Asimismo se han utilizado para encontrar patrones de fraude económico, hacer predicciones en el mercado financiero, hacer predicciones de tiempo atmosférico, etc.

También se pueden utilizar cuando no existen modelos matemáticos precisos o algoritmos con complejidad razonable; por ejemplo la red de Kohonen ha sido aplicada con un éxito más que razonable al clásico problema del viajante (un problema para el que no se conoce solución algorítmica de complejidad polinómica).

Otro tipo especial de redes neuronales artificiales se ha aplicado en conjunción con los algoritmos genéticos (AG) para crear controladores para robots. La disciplina que trata la evolución de redes neuronales mediante algoritmos genéticos se denomina Robótica Evolutiva. En este tipo de aplicación el genoma del AG lo constituyen los parámetros de la red (topología, algoritmo de aprendizaje, funciones de activación, etc.) y la adecuación de la red viene dada por la adecuación del comportamiento exhibido por el robot controlado (normalmente una simulación de dicho comportamiento)

### **3.12. Conclusiones parciales.**

En resumen, en este capítulo hemos propuesto el tema de las redes neuronales, sus características básicas y sus diferentes aplicaciones, así como las ventajas.

- Al final del capítulo hemos presentado diferentes estrategias generales para entrenar las redes neuronales.

- Aprovechando las bondades que ofrecen las RNA, Se tiene la arquitectura de modelos neuronales para detectar ondas sinusoidales con diferentes irregularidades.

- La arquitectura más adecuada de una RNA para detectar señales sinusoidales ha resultado ser de tipo incremental adaptativa, de propagación hacia adelante.
- Resulta interesante el proceso de ajuste de la red neuronal para garantizar un efectivo entrenamiento y aprendizaje.



## **Capítulo IV Implementación del estimador neuronal para el diagnostico del accionamiento**

### **4.1 Introducción.**

En este capítulo se describe y simulan las señales de las variables principales que participan en la operación del sistema de accionamiento eléctrico con motor de inducción y bombas centrífugas ; a través de módulos basados en una red neuronal con arquitectura FEED FORWARD, con el objetivo de poder predecir el comportamiento del motor y próximos a averías

Se realiza la simulación del sistema de accionamiento eléctrico sobre la base de patrones de variables obtenidos desde la práctica. En aras de facilitar su futura implementación, se ofrecen los ficheros elaborados desde el MATLAB, y las especificaciones de los módulos de las variables de los subsistemas de potencia del motor de inducción y el subsistema mecánico de la bomba centrífuga con la instalación hidráulica.

### **4.2 Patrones cognoscitivos de una red neuronal obtenidos a través de las principales zonas de fallas con ayuda del software Matlab.**

La red que se mostrara a continuación será la encargada de la predicción de todos las fallas o avería .Esta formada por una red multiseñal para el diagnostico de motor según las señales de los patrones para las cuales este entrenada esta.




Figura 1: red de de predicción de avería.

Modelo simplificado de la red neuronal artificial




Figura 2. Modelo simplificado.  
Representación de la red neuronal según sus capas de entradas y de salida.




Figura 3. Esquema según las capas de entradas y salidas

## Modelo ampliado de la red neuronal artificial aplicado a los patrones de tensión




Figura 4. Obtención de la onda según la red neuronal.

### 4.2.1 Patrones tensión, corriente, temperatura y potencia del motor de inducción.

La red neuronal está entrenada para reproducir el comportamiento de la variable sinusoidal de tensión y corriente, por ejemplo de la fase B y C como se observa en la figura 1. Donde se muestran los diferentes gráfico que demuestran la deformación de las señales de entrada y salida donde se observa la forma en que la RNA puede ir monitoreando las variables, y en este caso es para su comportamiento a normal, es decir supera excesivamente en rms sus rangos.

Se muestran los gráficos más significativos del motor que fueron obtenidos a través del MATLAB, que serán utilizados como patrones de prueba.

#### Programación de la red.

```
% --- Red de prueba FEED DOWARD ---
%P = [0 1 2 3 4 5 6 7 8 9 10];
%T = [0 1 2 3 4 3 2 1 2 3 4];

% --- Las entradas en P de la red Ua tensión de la fase A ---
P=[0 0.1165 0.26135 0.39693 0.5998 0.6477 1.0111 0.93795 1.1652
1.026 ...
1.061 0.76468 0.73838 0.80006 0.4516 0.39272 0.10512 -0.071932 -0.39047
...
-0.56957 -0.5134 -0.76129 -0.95147 -1.0281 -0.90752 -1.0018 -0.90758
...
-0.84379 -0.69714 -0.59122 -0.59874 -0.24191 0.029427 0.18941 0.073796
...]
```

```
0.46674 0.62469 0.82547 0.84759 0.96772 1.1592 1.0741 0.96754 0.76225
...
0.72735 0.59971 0.35641 0.18922 0.066298 -0.018545 -0.61091 -0.65384;
...
0 0.1165 0.26135 0.39693 0.5998 0.6477 1.0111 0.93795 1.1652 1.026 ...
1.061 0.76468 0.73838 0.80006 0.4516 0.39272 0.10512 -0.071932 -0.39047
...
-0.56957 -0.5134 -0.76129 -0.95147 -1.0281 -0.90752 -1.0018 -0.90758
...
-0.84379 -0.69714 -0.59122 -0.59874 -0.24191 0.029427 0.18941 0.073796
...
0.46674 0.62469 0.82547 0.84759 0.96772 1.1592 1.0741 0.96754 0.76225
...
0.72735 0.59971 0.35641 0.18922 0.066298 -0.018545 -0.61091 -0.65384];

% --- Salida T de la red Us tensión de la fase A ---
T=[0 0.1165 0.26135 0.39693 0.5998 0.6477 1.0111 0.93795 1.1652 1.026 ...
1.061 0.76468 0.73838 0.80006 0.4516 0.39272 0.10512 -0.071932 -0.39047
...
-0.56957 -0.5134 -0.76129 -0.95147 -1.0281 -0.90752 -1.0018 -0.90758
...
-0.84379 -0.69714 -0.59122 -0.59874 -0.24191 0.029427 0.18941 0.073796
...
0.46674 0.62469 0.82547 0.84759 0.96772 1.1592 1.0741 0.96754 0.76225
...
0.72735 0.59971 0.35641 0.18922 0.066298 -0.018545 -0.61091 -0.65384];

%--- Se ha creado una red FEED FORWARD con dos capas.
%El rango de las entradas es de [-1 a 1]. Las dos capas de
entrada tienen cinco
%- neuronas, con una función tansig, la capa de salida tiene una
%neurona, con una purelin. Se usa entrenador Levenberg- Marquard.

net = newff([-1 1;-1 1],[5 5 1],{'tansig' 'tansig' 'purelin'});

% Here the network is simulated and its output plotted against
% the targets.

Y = sim(net,P);
plot(P,T,P,Y, 'o')

pause

% Here the network is trained for 50 epochs. Again the network's
% output is plotted.

net.trainParam.epochs = 50;
net = train(net,P,T);

% Genera el bloque Simulink que representa la Red Neuronal
% entrenada y con el -1 se indica que se puede modificar ts.
gensim(net,-1).
```

**A continuación se muestran los gráficos de las señales de tensión obtenidos a través de mediciones. Que serán utilizados como patrones en la detección de fallas o averías en accionamientos con motores de inducción con bombas**

En este gráfico se muestra como la señal de tensión de las mediciones varía en comparación con la señal entregada por la red neuronal al motor de inducción. Se puede ver que la señal de las mediciones no es sinusoidalmente perfecta, puesto que está en presencia de distorsiones que afectan el equipamiento del accionamiento.

Este tipo de representación tiene como ventaja la facilidad de hacer una comparación entre la señal que entrega el variador de velocidad y la mejor señal entregada por la red neuronal artificial.

**Patrón tensión para la fase B y C, donde la red neuronal muestra un comportamiento anormal de la onda de tensión**




Figura 5. Desbalance de 30 grados y hasta un 40 % en valores de rms entre las tensiones de fases  $U_b$  y  $U_c$ .

**Patrón tensión para la fase B y C, donde la red muestra un comportamiento anormal de la onda existiendo un des balance de fase según el ángulo**




Figura 6. Desbalance de 30 grados entre las tensiones de fases  $U_b$  y  $U_c$ .

**Patrón tensión para la fase B y C, donde la red muestra un comportamiento anormal y la deformación de la onda de tensión**




Figura 7. Las tensiones de fases están desfasadas 120 grados eléctricos.

**Patrón tensión para la fase B y C, donde la red muestra un comportamiento anormal de la onda y la deformación de la onda de tensión según el ángulo de desfasaje**




Figura 8. Las tensiones de fases  $U_b$  y  $U_c$  están desfasadas 45 grados eléctricos.

En los gráficos anteriores se han representados las señales de la onda de tensión de cada fase en conjunto con la entregada por la red neuronal utilizada, representando las deformaciones de la onda de tensión así como la señal obtenida como patrón por la red. Estas señales se encuentran desfasadas en cada gráfica (30, 120, 45) grados eléctricos respectivamente.

A continuación presentamos a la red neuronal artificial que será utilizada para el diagnóstico y control de averías aplicado a señales de tensión. Utilizando los modelos o patrones obtenidos en las gráficas anteriores.

Programa para la obtención de gráficos de la onda de tensión utilizando Matlab.

#### Programación

```
% --- Medicion tension fase A
Uc;Ub;Umod;
%Iest;Mem;rpm;Udc;
subplot(3,1,1),plot(Uc(:,1),Uc(:,2)),grid
xlabel('tiempo [s]')
ylabel('tension fase c [V]')
title('Tension en fase c')
```

```
subplot(3,1,2),plot(Ub(:,1),Ub(:,2)),grid
xlabel('tiempo [s]')
ylabel('tension fase B [V]')
title('Tension en fase B')
subplot(3,1,3),plot(Umod(:,1),Umod(:,2)),grid
xlabel('tiempo [s]')
ylabel('tension Umod [V]')
title('Onda modelo de Tension')
```

En la figura 9 representamos las señales de las fase B y C con la onda de tensión entregada por la red donde nos muestra las deformaciones de la señal de la onda en cada una independientemente.

Gráficos de tensiones de fases y tensión entregada por la Red Neuronal Artificial




Figura 9:

Modelo distorsión de la onda de tensión de las fase B y C con salida de la red.






Figura 10: obtención del modelo de la densidad espectral y modelo de la onda de tensión.

En esta figura podemos observar la representación de la densidad espectral de potencia en conjunto con las señales de la onda de tensión modelo y la de la fase B. Podemos decir que esta señal es obtenida a través del filtrado de la señal de salida, representado el buen estado de funcionamiento de motor de inducción.

En la figura 11 (a) y (b) representamos a la densidad espectral de potencia obtenida de la relación potencia/frecuencia en (dB/Hz) y la frecuencia (kHz).

La figura (a) nos muestra que el motor está presentando problema debido a la intersección que existe entre las dos señales. Entre mayor separación exista entre las curvas más estable es el funcionamiento de motor.

Densidad espectral de potencia.




Figura11 a: Densidad espectral de la potencia.




Figura11 b: Densidad espectral de la potencia.

En esta figura mostramos las señales de fase en conjunto con la onda de tensión modelo representando las pequeñas deformaciones de la onda de tensión




Figura12: Modelo distorsión de la onda de tensión de las fases B y C con la onda modelo. La grafica 13: representa el aprendizaje de la red en 50 iteraciones.

Mostrándonos el error de aprendizaje de la red neuronal artificial




Figura 13: Esquema de aprendizaje de la red.

Editor para el trabajo con Redes Neuronales en Matlab.




Figura 14: Esquema de trabajo de la red.




Figura15: representa el comportamiento de la red.

Representa el buen comportamiento de la red debido a que el chequeo de validación es aproximadamente lo más cercana a cero igual que el gradiente en 50 iteraciones. Significa que está aprendiendo (epochs).




Figura 16: demostración del aprendizaje de la Red (función regresión).

Esta figura representa el aprendizaje de la red utilizando la función de regresión, con esta nos muestra el buen funcionamiento a la hora de trabajar e identificar las señales la cual es utilizada por la Planta demostrando que la red a aprendido  $Y=T$ , esto lo demuestra el factor  $R=1$ .

#### **4.3 Patrones frecuencia (vibraciones), obtenidas para el accionamiento del motor de inducción acoplado a una bomba centrífugas**

En este trabajo se van a ofrecer una serie de patrones relacionados con el efecto de las vibraciones que tiene lugar en los mecanismos industriales donde intervienen turbo-máquinas.

Normalmente las vibraciones son medidas a través de acelerómetros que miden las vibraciones a través de señales y mediante éstos se detectan fallas en el sistema.

En la industria del níquel es frecuente el uso de accionamiento con bombas centrífugas y para medir adecuadamente las vibraciones en estos sistemas se sugiere utilizar dos sensores de tipo acelerómetro, uno en el motor de inducción, y

otro en el cuerpo de la bomba centrífuga, la frecuencia de muestreo de las señales de vibraciones son medidas a 50 kHz y el tiempo de muestreo es de 10 segundos, las señales de las vibraciones son medidas para una velocidad de rotación del motor constante y para un flujo o gasto fijo de la bomba centrífuga. Se tienen como datos 1500 rpm y 190 m<sup>3</sup>/h para el bombeo de agua y licor laterítico.

La cavitación es una de las fuentes de inestabilidad en las bombas centrífugas la cual provoca efectos indeseables y deteriora progresivamente los aditamentos, accesorios y equipos del sistema hidráulico, además ocasiona caídas de la altura de carga y las curvas de eficiencia de la bomba. La presencia del licor laterítico causa además la erosión, el desgaste, ruidos indeseados de considerables efectos nocivos. Otros efectos indeseados en el sistema de bombeo son desbalances en los impelentes o rodets de trabajo de la bomba centrífuga, desalineación del acoplamiento entre el motor y la bomba, etc.

En este trabajo se elaboran patrones tomando la experiencia registrada en el artículo "Intelligent diagnosis method for a centrifugal pump using features of vibration signals", en la revista Neural comput & application (2009) del autor Huaqing Wang- Peng Chen.

La construcción de los patrones para el diagnóstico se basa en utilizar las señales medidas, en este caso para el fenómeno de las vibraciones y sin explicar con profundidad el procesamiento de las señales se brindan algunos programas que identifican las señales ya procesadas sobre el fenómeno de la vibración en las máquinas rotatorias.

Para la interpretación correcta de los patrones es importante conocer los niveles de frecuencia en las que son obtenidos y los autores Huaqing Wang- Peng Chen reflejan en su investigación una clasificación que es retomada en este trabajo.

La idea del diagnóstico, es la utilización de las redes neuronales para identificar los patrones para cada tipo de falla en el accionamiento con motores de inducción, en especial para accionar bombas centrífugas en la industria del níquel.

Como se tiene una base de conocimiento acerca del comportamiento de las señales que identifican el fenómeno de las vibraciones en los accionamientos de instalaciones de bombeo, se aprovechan los resultados del tratamiento mediante

la transformada de las señales y la adquisición de ellas a través de una red neuronal básica.

El presente estudio aporta una serie de patrones que pueden ser utilizados para el diagnóstico de accionamiento de bombas centrífugas cuando las condiciones de operación tienen presentes niveles de vibraciones relativamente altos en la tabla 4.1 se muestran el rango de frecuencia para cada nivel.

La tabla 4.1 muestra las regiones de frecuencia según los niveles de esta.

|                    |                     |              |                     |
|--------------------|---------------------|--------------|---------------------|
| $A_0$ (Original)   | 0 ~ 50 kHz          |              |                     |
| Aproximaciones (A) | Rango de frecuencia | Detalles (D) | Rango de frecuencia |
| Level $A_1$        | 0 ~ 25 kHz          | Level $D_1$  | 25 ~ 50 kHz         |
| Level $A_2$        | 0 ~ 12.5 kHz        | Level $D_2$  | 12.5 ~ 25 kHz       |
| Level $A_3$        | 0 ~ 6.25 kHz        | Level $D_3$  | 6.25 ~ 12.5 kHz     |
| Level $A_4$        | 0 ~ 3.125 kHz       | Level $D_4$  | 3.125 ~ 6.25 kHz    |
| Level $A_5$        | 0 ~ 1.5625 kHz      | Level $D_5$  | 1.5625 ~ 3.125 kHz  |
| Level $A_6$        | 0 ~ 781.25 Hz       | Level $D_6$  | 781.25 ~ 1562.5 Hz  |
| Level $A_7$        | 0 ~ 390.63 Hz       | Level $D_7$  | 390.63 ~ 781.25 Hz  |
| Level $A_8$        | 0 ~ 195.31 Hz       | Level $D_8$  | 195.313 ~ 390.63 Hz |

En el caso particular de las maquinas rotatorias, las señales de vibración son muy dañinas debido a esto se realizan una variedad de mediciones de frecuencias para obtener los patrones y efectuar la detección de fallas, lo mismo en motores de inducción que en bombas. Tabla 4.1.

Con la obtención de los siguientes vectores conseguimos realizar las graficas para la identificación de las señales de vibración y así poder utilizarlos en la identificación de esta falla mediante la red neuronal artificial construida.

Vector 1: [0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0];

Vector 2: [0 0 0 0 0 - 0.1 0.25 -0.6 1 -0.6 0.25 -0.1 0 0 0 0 0 0 0];

Vector 3: [0 0 0 0 0 -0.1 0.2 -0.4 1.5 -0.4 0.2 -0.1 0 0 0 0 0 0 0];

Vector4: [0 0 0 0 0 0 -0.2 0.4 -1.2 1.6 -1.2 0.4 -0.2 0 0 0 0 0 0 0];

De estos vectores obtuvimos los modelos de vibraciones siguientes y los patrones de salida de **la red neuronal básica radial** utilizada para la detección de este tipo de fallas.

Los niveles A de las señales corresponden a vibraciones de bajas frecuencias y los niveles D corresponden a señales con rango de frecuencia alta.

Aunque los autores del artículo referenciado en este trabajo (Huaqing Wang- Peng Chen) Construyeron una red neuronal particularmente linealizada, el presente trabajo utiliza los resultados del procesamiento matemático de estos autores.

Huaqing Wang y Peng Chen utilizaron en su estudio una red neuronal tipo “back propagation”, lo cual fue adecuado para el procesamiento matemático de las señales. Para cumplir el objetivo del presente trabajo este aspecto se simplificó utilizando una red básica radial.

Las señales de vibraciones fueron medidas para ocho estados de carga del accionamiento, y son descompuestos en ocho niveles de alta y baja frecuencia.

Para el caso de los accionamientos de bombas centrífugas utilizadas en la industria del níquel los niveles de vibraciones presentes se encuentran entre los niveles A2 y A6 y D2 y D6, según los expedientes que se tienen en los talleres eléctricos de mantenimiento de la empresa Cmdte. Ernesto Che Guevara de Moa y la Empresa mecánica Cmdte. Gustavo Machín.

De acuerdo a los especialistas Huaqing Wang y Peng Chen, la verificación de los resultados arrojados por la red neuronal y comparándolo con las señales reales, se concluyó que las probabilidades del estado normal del accionamiento puede ocurrir en un 79.3 %, el estado de cavitación en un 85.1 %, la desalineación 14.8 % y el estado del desbalance 61.2 % respectivamente.

Los diferentes estados aparecen en diferentes niveles de frecuencia, la recomposición de las señales que son obtenidas detectaron un máximo de rango de 99.6 % para el nivel A1 para distinguir el estado normal desde estados anormales el máximo de detección fue de 96.1 % del nivel D2 para distinguir el estado de cavitación, fenómeno muy frecuente en los accionamientos de la industria del níquel y tuvo un máximo de detección de 99.9 % del nivel A2 para distinguir el estado de desalineación y un máximo de detención de 83.7 % del nivel A2 para distinguir desbalances debido al deterioro del impelente de la bomba centrífuga.



El método de diagnóstico utilizando redes neuronales es efectivo cuando se tienen en cuenta varias señales que identifican diferentes tipos de fallas y en este trabajo se atiende aquellas señales que más se identifican con los patrones obtenidos neuronalmente.

### **Modelo utilizado para diagnosticar fallas o averías por vibraciones.**




Figura 17: Descomposición escalonada de la función  $\phi(\varphi)$ .

Modelo utilizado para diagnosticar fallas o averías por vibraciones.




Figura 18: descomposición wavelet función  $\phi(\varphi)$ .

Modelo utilizado para diagnosticar fallas o averías por vibraciones.




Figura 19: reconstrucción escalonada de la función  $\phi(\varphi)$ .

Modelo utilizado para diagnosticar fallas o averías por vibraciones.




Figura 20: reconstrucción wavelet función  $\phi(\phi)$ .

#### Programación de la red de vibraciones

```
% *** Neuronas básicas radiales ***  
% Una red básica radial es entrenada para responder a entradas  
% específicas  
% con salidas target. Asimismo, debido a que el spread de las neuronas  
% básicas radiales es también alta, cada neurona responde esencialmente  
% igual y la red no puede ser diseñada.  
%  
% Copyright 1992-2002 The MathWorks, Inc.  
% $Revision: 1.16 $ $Date: 2002/04/14 21:28:23 $  
  
% se definen 21 entradas P asociadas con salidas targets T.  
  
P = -1:1:1;  
T = [0 0 0 0 0 -0.1 0.2 -0.4 1.5 -0.4 0.2 -0.1 0 0 0 0 0 0 0 0];  
plot(P,T,'+');  
title('Vectores entrenados');  
xlabel('Vector de entrada P');  
ylabel('Vector de salida T');  
  
% La función NEWRB crea rápidamente una red básica radial la cual  
% aproxima  
% la función definida por P y T.  
  
% En adición al ajuste del y los targets, NEWRB toma dos argumentos, the  
% sum-squared error goal and the spread constant. El spread de la red  
% básica radial B es ajustado a un número extenso.  
% donde:  
eg = 0.01; % es sum-squared error goal
```

```
sc = 0.38; % spread constant
net = newrb(P,T,eg,sc);

% La función NEWRB no puede diseñar propiamente su red radial
% básica debido al extenso proceso de ajuste en la región de entrada de
% la
% red. Todas las neuronas siempre tienen una salida 1 y no pueden generar
% diferente respuesta. Para ver cómo la red se procesa con el ajuste del
% entrenamiento, se simula la red con las entradas originales.
% Se plotean los resultados en el mismo gráfico de los ajuste del
% entrenamiento.

Y = sim(net,P);
hold on;
plot(P,Y),grid;
hold off;
gensim(net,-1)
```

### **Patrones de señales de vibración entregada por la Red Neuronal Artificial.**




Figura 21: modelo de vibración obtenido de la red.

### **Patrones de señales de vibración entregada por la Red Neuronal Artificial.**




Figura 22: modelo de la onda de vibración obtenido de la red.

### **Patrones de señales de vibración entregada por la Red Neuronal Artificial.**




Figura 23: modelo de la onda de vibración obtenida de la red.

### **Patrones de señales de vibración entregada por la Red Neuronal Artificial.**




Figura 24: modelo de la onda de vibración obtenida a través de la red neuronal radial artificial.

#### 4.4 Conclusiones

- Se elaboraron los patrones de las fallas típicas en el motor de inducción y la bomba centrífuga a partir del tratamiento de señales que identifican las averías correspondientes a desbalances de fase de tensión, vibraciones y cavitación.
- Se utilizó una red neuronal tipo feed forward para la identificación de las señales de tensión desbalanceadas, con tres capas, con funciones de activación tipo tansig y purelin.
- Se usó una red básica radial para la identificación de los espectros de las señales de vibraciones, a partir de una base de conocimiento ofrecida por los especialistas Peng y Chen.
- Se tiene los rangos de frecuencia correspondientes a las condiciones de explotación de los accionamientos de bombas centrífugas para la industria del níquel. A2 –A6, y D2 –D4.

# Capítulo V Evaluación Técnico-Económica

## 5.1 Introducción

Para representar la incidencia que tiene el efecto de cualquier avería que pueda ocurrir en uno de los accionamientos de bombas centrífugas que transportan pulpa laterítica, se tiene un estudio económico del sistema en la empresa Cmdte. Ernesto Che Guevara de Moa.

Con el objetivo de mostrar el impacto que ocasionar una hora fuera de servicio de estos accionamientos con motores de inducción, se cuantifican las pérdidas actuales, así como su costo y la relación costo beneficio.

## 5.2 Valoración económica

La producción de níquel por el proceso CARON constituye uno de los métodos de mayor consumo energético en la industria nacional. Actualmente una tonelada de níquel obtenida por este proceso consume más de 10 MW\*h de energía eléctrica y constituye más del 20 % del costo de producción, y esto se refleja en el nivel de vida de la población. Es por esto que la eficiencia en el uso de la energía eléctrica tiene un impacto tanto económico como social.

En las plantas minero metalúrgicas como las de Moa y Nicaro, se precisan que los mayores consumidores de energía eléctrica lo representan los accionamientos con motores eléctricos de: producción de aire comprimido, las bombas centrífugas, las instalaciones de molienda y secado y los ventiladores de tiro forzados. Los accionamientos de bombas centrífugas están entre los accionamientos más empleados en el proceso de obtención de níquel ya sea por tecnología Carbonato amoniacal o por Lixiviación Ácida.

En la práctica en la empresa Comandante Ernesto Che Guevara de Moa se suele estrangular por la succión logrando el mismo efecto hasta que la caída de presión en la línea de succión alcanza la temperatura de vapor del fluido y aparece el fenómeno de la cavitación. En esencia la introducción de una red neuronal que

controle y monitoree el accionamiento y más si esta elevado a disminuir las averías, permitiendo la disminución de las pérdidas de energía y aumenta el tiempo de vida útil o empleo de la bomba y motores.

**Es bueno indicar que con el aumento de las pérdidas no sólo disminuye el rendimiento sino también empeora el factor de potencia del motor eléctrico.**

El cálculo económico está dado por las horas en que puede existir cualquier avería en los accionamientos con motores y bombas representando un gasto en reparaciones o remplazo de los mismos que puede significar cuando utilizamos la red neuronal artificial para la predicción y detección de fallas o averías o en el incremento del tiempo de vida útil de la instalación.

Para la implementación de la red lo primero que se debe tener en cuenta es la compra de una gran variedad de sensores que facilita la toma de mediciones en el banco de motor o las bomba en las que van a ser instalados, lo cual implica un porcentaje de inversión debido a que estos deben ser de gran fiabilidad y lo cual su costo es muy variado.

Si se utiliza en el accionamiento eléctrico de motores con bomba centrífuga un controlador que regulara el caudal de la bomba de acuerdo con la velocidad se evitaría frecuentemente las perturbaciones por régimen de cavitación y se ahorrarían 3,2 \$ CUC por cada ( ) de pulpa transportada, es sobre el gasto que representa el uso de la red neuronal en el sentido de evitar cualquier avería o fallas relacionada con las causas que afectan el buen funcionamiento del motor o la bomba centrífuga, provocando un mal funcionamiento del accionamiento.

**1-** Si se implementara la compra de los sensores requeridos para tomar una serie de mediciones sobre las cuales trabaja la red neuronal multiseñal se obtendrá una disminución de las pérdidas causadas por los motores y se evitarían la reparación inmediata de otros según su uso y variedad.

**2-** Sin implementar la red neuronal en la industria, se averían alrededor de un 35% de los motores y un 17% de las bombas, según su utilización y clasificación.



**3-** Implementando la red multiseñal el % de cada uno disminuiría en el orden de 10% a 15.5% en los motores según su potencia y su uso, en las bombas aproximadamente 11.3%.teniendo en cuenta que los problemas en estas que suelen estar causados por fallas de cavitación, rodamientos o desgastes de sus partes móviles.

**4-** Implementando la red también disminuirían los sobre consumos de energía en motores con cargas variables, aumentando la vida útil y disminuyendo las perdidas en la instalación.

**5-** Normalmente cuando se avería un motor, según el problema que le haya ocasionado su rotura, la empresa debe invertir un dinero para su reparación, el cual este sería menor si se pudiesen diagnosticar a **tiempo** las posibles fallas que afectan el buen funcionamiento del accionamiento.

### **5.3. Conclusiones**

- Se elaboraron los patrones de las principales fallas que ocurren los accionamientos con motores de inducción a partir del tratamiento de las señales que identifican sus averías más frecuentes, usando la técnica de redes neuronales artificiales, que permiten el diagnóstico a partir de un estimador neuronal.
- Las fallas más frecuentes en el motor de inducción y la bomba centrífuga a partir del tratamiento de señales son identificadas como: desbalances de fase de tensión, vibraciones y cavitación.
- - Se utilizó una red neuronal tipo feed forward para la identificación de las señales de tensión desbalanceadas, con tres capas, con funciones de activación tipo tansig y purelin.
- - Se usó una red básica radial para la identificación de los espectros de las señales de vibraciones, a partir de una base de conocimiento ofrecida por los especialistas Huaqing Wang y Peng Chen.
- - Se tiene los rangos de frecuencia correspondientes a las condiciones de explotación de los accionamientos de bombas centrífugas para la industria del níquel. A2 –A6, y D2 –D4.

### **Recomendaciones**

- Extender el presente estimador neuronal para el diagnóstico a otros tipos de fallas, como el rotor bloqueado y bajo aislamiento.
- Obtener una base de datos más estrecha en accionamientos de otros mecanismos en la industria del níquel.

## **Bibliografía**

1. Fitzgerald, A. E.; Kingsley, Ch.; Umans, S.: "Electric Machinery", Ed. Mc. Graw Hill.
2. Ivanov - Smolensky, A.V.: "Máquinas Eléctricas", Editorial Mir, Moscú.
3. Klingshern, E; Jordan, H. E.: "Polyphase Induction Motor Performance and Losses on Nonsinusoidal Voltaje Sources", IEEE Transactions on Power Apparatus and Systems, Vol.87, No.3, 1968.
4. Bishop, Christopher M: Neuronal networks for pattern regonition. Oxford. Clarendon Press. 1990.
5. Lippmann, R. P: An introduction to computing with neuronal nets. IEEE ASSP Magazine, PP. 4-22, April 1987.
6. Haykin, S: Neural networks. A comprehensive fundation. 1994. Macmillam College Publishing Company Inc.
7. Trzynadlowski, A. M.; Legowski, S: Application of neural networks to the optimal control of three phase voltage controlled inverters. IEEE Trans. On Power Electron, Vol. 9, No 4, PP. 397-404, July 1994.
8. Intel Corp.: Neural network solution. 1991.
9. Forschungszentrum Karlsruhe, FZK; Institut fur Mikrelektronik Stuttgart IMS: "Sand" Powerful neuroprocessor for intelligent system. Notes 8/1997.
10. Headquarters, dSPACEmbh; USA y Canada, dSPACEInc; dSPACE Solutions for control. DS1103 PPC controller board new products. Summer 1998
11. SIEMENS A&D SD CS Service Cooperation 1995,
12. FAG SOUTH EAST ASIA PTE LTD 2002).
13. Silva, Márquez Cardoso, 2005); SIEMENS A&D SD CS Service Cooperation, 1995; FAG SOUTH EAST ASIA PTE LTD, 2002)
14. Silva, Marquez Cardoso, 2005
15. Fitzgerald, et al., 2004).
16. La norma de la IEEE a la que hacemos referencia es la IEEE 43-2000
17. © FUOC • P01/79008/00057 25 Inteligencia artificial

18. Rosaler, Robert C. (2002). Manual del Ingeniero de Planta. Mac-Graw-Hill/Interamericana de Editores, S.A. de C.V.
19. Bittel, L./Ramsey, J. (1992). Enciclopedia del MANAGEMENT. Ediciones Centrum Técnicas y Científicas. Barcelona, España.
20. Rios, A., Mousalli, G., & Rivas, F. (2002). *Invertibility and neural networks based FDI filter*. En IASTED international conference on intelligent systems and control. Tsukuba – Japan.
21. Massoumnia, M. (1986). *A geometric approach to the synthesis of failure detection filters*. IEEE Trans. Aut. Control, 839-846.
22. <http://www.solomantenimiento.com/>
23. <http://www.mantenimientomundial.com/>

