

Sistema experto para la definición de umbrales adaptivos en procedimientos de mantenimiento en transmisión eléctrica

Yolanda Llosas1, Italo Navarrete1, Ney Balderramo1, Gabriel Pico1, Julio Guamán 1
Departamento de Ingeniería Eléctrica, Universidad Técnica de Manabí, Portoviejo, Ecuador.
Ave Urbina y Ché Guevara, Portoviejo
yllosas@utm.edu.ec., inavarrete@utm.edu.ec

Abstract— In the work the design of a connectionist expert system is realized, which uses tools of the artificial intelligence that allow the decision making for the establishment of adaptive thresholds as classifiers of the type of maintenance to be used. For the selection of a maintenance in electrical systems in general, parameters and conditions are taken into account that facilitate an adequate selection of the maintenance to be applied, for that reason the incidences of a failure, are limited in selection ranges of a maintenance for each incidence ; From 0 - 0.49 preventive maintenance is considered, taking into account the technology of the material to be used, the experience acquired by the personnel in charge of maintenance and considering the presence of a passive hot spot in all the electrical installations in full operation; Of 0.5 - 0.69 is considered a predictive maintenance, with presence of an active hot spot, in this maintenance an additional range of 0.7 - 0.79 is considered considering a proactive maintenance due to the possibility of some failure, Of 0.8 - 1.0 is considered a corrective maintenance, for the equipment change. It builds the system starting from the acquisition of the data for the construction of the database, the machine inference expert system based on the operators' expertise and the human machine interface in a comfortable, friendly and reliable manner. The results are displayed on the computer screen, and the connection system database is available for other applications.

Index Terms— artificial intelligence, expert system, failures, maintenance, classifiers.

I. INTRODUCCION

En los últimos 30 años, el diagnóstico de fallos ha adquirido gran importancia debido a las ventajas potenciales que pueden obtenerse en la reducción de los costes de mantenimiento y reparación, el mejoramiento de la productividad y el aumento de la seguridad y disponibilidad de los procesos industriales. En este sentido, una rápida detección del problema puede ayudar a tomar decisiones correctivas y reducir el daño potencial que los fallos pueden ocasionar al sistema. Para estos casos, las técnicas de diagnóstico permiten mejorar no sólo la eficiencia del proceso, sino además, la operatividad, mantenibilidad y fiabilidad de dichos sistemas.

Al revisar la literatura propia de este tema, se pueden encontrar múltiples enfoques los cuales puede ser clasificados de manera general en métodos basados en modelos [1, 2] y métodos basados en datos históricos [3, 4].

Debido al avance de la automatización en la industria, los métodos basados en datos históricos adquieren una gran importancia por la elevada cantidad de información que existe de los procesos, almacenada en las bases de datos de los sistemas de supervisión, control y adquisición de datos

(SCADA por sus siglas en inglés). Dado que existe una gran cantidad de métodos para el análisis de la información almacenada, es importante realizar un estudio comparativo entre las técnicas de clasificación más utilizadas históricamente para el diagnóstico de fallos en procesos industriales, y otras técnicas de reciente surgimiento con excelente desempeño en el reconocimiento de patrones. El objetivo es determinar las técnicas con mayor capacidad para clasificar de forma correcta patrones de fallos en los procesos industriales a partir del análisis de los datos históricos provenientes de los mismos. Lo anterior permitirá a los especialistas ganar en elementos para evaluar y decidir qué técnica utilizar a partir de la aplicación que se esté analizando.

En el trabajo se realiza el diseño de un sistema experto conexionista, el cual emplea herramientas de la inteligencia artificial que permiten la toma de decisiones para el establecimiento de umbrales adaptivos como clasificadores del tipo de mantenimiento a emplear.

Para la selección de un mantenimiento en sistemas eléctricos en general, se toman en cuenta parámetros y condiciones que faciliten una adecuada selección del mantenimiento a aplicar, por tal motivo la incidencias de un fallo, se limitan en rangos de selección de un mantenimiento para cada incidencia; Desde 0 – 0,49 se considera un mantenimiento preventivo, teniendo en cuenta la tecnología del material a utilizar, la experiencia adquirida por el personal encargado de mantenimiento y considerando la presencia de un punto caliente pasivo en todas las instalaciones eléctricas en pleno funcionamiento; de 0,5 - 0,69 se considera un mantenimiento predictivo, con presencia de un punto caliente activo, en este mantenimiento se considera un rango adicional de 0,7 – 0,79 considerando un mantenimiento proactivo debido a la posibilidad de algún fallo, de 0,8 – 1,0 se considera un mantenimiento correctivo, para el cambio del equipo. Se construye el sistema partiendo de la adquisición de los datos para la construcción de la base de datos, la máquina de inferencia del sistema experto en base a la experticia de los operadores y la interfaz humano máquina de forma cómoda, amigable y confiable.

Los resultados se deben visualizar en la pantalla de la computadora, quedando además la base de datos del sistema conexionista disponible para otras aplicaciones.

II. MATERIALES Y MÉTODOS

En procesos complejos, ocurre que no existen sus modelos matemáticos. De igual manera en ocasiones se hacen complejos los problemas de optimización por los volúmenes de la minería de datos y la no linealidad de las funciones que en ocasiones toman enfoques borrosos o de dinámica variable ante variación de las condiciones dinámicas en el tiempo del uso del mallado de sus redes.

Una forma de obtener dichos modelos o buscar el mejor es a partir de los datos de entrada/salida, en situación de buen funcionamiento es utilizando técnicas denominadas de soft-computing lo cual garantiza el trabajo efectivo y eficiente de la detección por las potencialidades que presentan las mismas para el tratamiento de la información de forma distribuida y paralela, lo cual hace al sistema que lo emplea muy robusto por su desempeño (Chen, 1999): por ello en este trabajo se usan las estrategias de control basados en conocimiento.

Se han venido destacando otros paradigmas como lo son los agentes de decisión inteligente y autómatas programables, con respecto a estos últimos se suelen emplear en gran medida en procesos industriales de acuerdo a necesidades a satisfacer como, espacio reducido, procesos de producción periódicamente cambiantes, procesos secuenciales, maquinaria de procesos variables, etc.

Un sistema experto (SE) es un sistema computacional, que simula a un experto humano en la solución de problemas de un dominio específico. Los sistemas expertos se basan en reglas que se confeccionan a partir de la experiencia del operador del proceso, y que se establecen como un conjunto de secuencias Si-Entonces (IF_THEN).

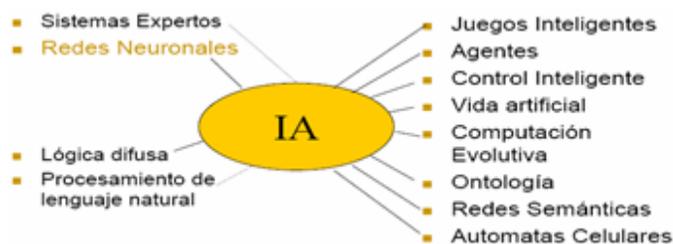


Figura 1. Empleo de los sistemas expertos-

Estos tipos de sistemas se emplean con gran rendimiento en sistemas supervisores, así como, combinados con otras técnicas de regulación.

Rasgos Fundamentales

1. Inferencia: Debe ser capaz de arribar a conclusiones con información parcial de las variables de entrada (no necesariamente se debe conocer toda la información).
2. Adquisición interactiva de datos: Debe ser capaz de obtener la información de manera cómoda y eficiente (interface)
3. Estructura modular: • Base de conocimiento

- Máquina de inferencia
- Interfaces con el medio

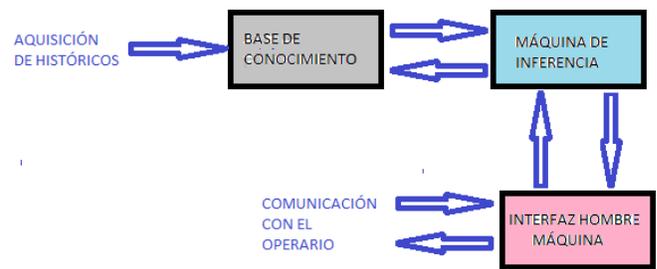


Figura 2. Módulos del Sistema Experto

Un SE debe ser capaz de resolver problemas complejos en dominios específicos, mostrando un nivel de desempeño comparado con el de los expertos humanos. Los SE por lo general contienen alguna experiencia, no algorítmica, para realizar tareas que requieren experiencia. Tareas que necesitan grandes espacios de búsqueda con conocimiento incierto.

- Clasificación
- Predicción
 - Diagnóstico
 - Reparación
 - Generación de planes
 - Interpretación
 - Diseño
 - Monitorización
 - Control

La mayor dificultad de los sistemas expertos radica en el tiempo necesario para elaborar su base de conocimiento, pues se necesita consultar varios expertos humanos y tomar los puntos de coincidencia de estos para dar mayor confiabilidad al sistema. En el caso del sistema energético del territorio implica el uso de sistemas de control inteligente en los que oportunamente se apliquen los sistemas basados en el conocimiento para los casos seleccionados.

El desarrollo de nuevos sistemas de tratamiento de la información, que permitan solucionar problemas cotidianos, tal como lo hace el cerebro humano; este órgano biológico cuenta con varias características deseables para cualquier sistema de procesamiento digital, tales como:

- Robustez y tolerancia a fallas: Diariamente mueren neuronas sin afectar su desempeño.
- Flexibilidad: Se ajusta a nuevos ambientes por aprendizaje, no hay que programarlo.
- Puede manejar información difusa, con ruido o inconsistente.
- Es altamente paralelo.
- Es pequeño, compacto y consume poca energía.

Las RNA han brindado una alternativa a la computación clásica, para aquellos problemas, en los cuales los métodos tradicionales no han entregado resultados muy convincentes, o poco convenientes.

Las aplicaciones más exitosas son:

- Procesamiento de imágenes y de voz.
- Reconocimiento y clasificación de patrones.
- Planeamiento.
- Interfaces adaptivas para sistemas Hombre/Máquina.
- Predicción y análisis.
- Control y optimización.
- Filtrado de señales.

A diferencia de los sistemas de cómputo tradicional, Las RNA no ejecutan instrucciones, responden en paralelo a las entradas que se les presenta. El resultado no se almacena en una posición de memoria, este es el estado de la red para el cual se logra el equilibrio. El conocimiento de una red neuronal y el poder de la red están en su topología y en los valores de las conexiones (pesos) entre neuronas.

Gracias a su robustez, capacidad de aprendizaje, no linealidad y tolerancia a la imprecisión, las RNA están alcanzando excelentes resultados, deberán emplearse donde ofrezcan ventajas, debe tenerse en cuenta una perspectiva global en la que se incluyan aspectos económicos, velocidad en desarrollo, fiabilidad, etc. Y no solo el rendimiento del sistema constituye así un útil y muy potente conjunto de herramientas que podemos añadir al gran número de métodos de procesamiento y control disponibles.

Las Redes Neuronales surgen en los 40 y en los 60 del siglo pasado dejan de desarrollarse. Las razones principales que motivaron el reinicio de los trabajos sobre redes neuronales en los años 80 son los siguientes:

1. Descubrimiento de algoritmos de aprendizaje potentes. Esto permitió crear redes que pudieran modelar cualquier tipo de región de decisión.
2. Avances tecnológicos alcanzados, entre ellos, la aparición de computadoras más rápidas sobre las cuales es posible simular grandes redes.
3. Necesidad actual de modelos computacionales paralelos.

Ventajas: El lazo extremo, consistente en el modelo de la planta y del optimizador, desaparecen una vez entrenada la red. El modelo de una neurona artificial es una imitación del proceso de una neurona biológica, que se asemeja a un sumador hecho con un amplificador operacional. El modelo se inspira en la operación biológica, en el sentido de integrar una serie de entradas y proporcionar cierta respuesta que se propaga por el axón. Existen varias formas de nombrar una neurona artificial, es conocida como nodo, neuronodo, celda, unidad o elemento de procesamiento (PE); Las entradas X_i representan las señales que provienen de otras neuronas y que son capturadas por las dendritas. Los pesos W_i son la intensidad de la sinapsis que conecta dos neuronas; tanto X_i como W_i son valores reales. (Es la función umbral que la neurona debe superar para activarse; este proceso ocurre biológicamente en el cuerpo de la célula. Las señales de entrada a una neurona artificial X_1, X_2, \dots , En son variables continuas en lugar de pulsos discretos, como se presentan en una neurona biológica. Cada señal de entrada pasa a través de una ganancia o peso, llamado peso sináptico o fortaleza de la conexión cuya función es análoga a la de la función sináptica de la neurona biológica. Los pesos pueden ser

positivos (excitatorios), o negativos (inhibitorios), el nodo sumatorio acumula todas las señales de entradas multiplicadas por los pesos o ponderadas y las pasa a la salida a través de una función umbral o función de transferencia. Donde f_i representa la función de activación para esa unidad, que corresponde a la función escogida para transformar la entrada neta en el valor de salida x_i y que depende de las características específicas de cada red.

Las variables de entrada y salida pueden ser binarias (digitales) o continuas (analógicas), dependiendo del modelo y la aplicación. Por ejemplo, un Perceptrón multicapa o MLP admite ambos tipos de señales. Así, para tareas de clasificación poseería salidas digitales $\{0,1\}$, mientras que para tareas de ajuste funcional de una aplicación multivariable continua, se utilizarían salidas continuas pertenecientes a un cierto intervalo.

El comportamiento de una red está determinado por conexiones sinápticas. Las conexiones sinápticas son direccionales, es decir, la información solamente fluye en un solo sentido (desde las neuronas presinápticas a las postsinápticas). En general las neuronas se agrupan en unidades estructurales llamadas capas. Las neuronas de una capa forman grupos neuronales y finalmente, el conjunto de una o más capas forman una red neuronal.

Tipos de Capas

1. Sensorial o de Entrada: Reciben datos procedentes del entorno.
2. De Salida: Son las que proporcionan la respuesta de la red neuronal.
3. Oculta: no tienen conexión directa con el entorno, es decir, no se conectan directamente a sensores ni efectores. Pueden existir en las redes multicapas una o varias capas ocultas.

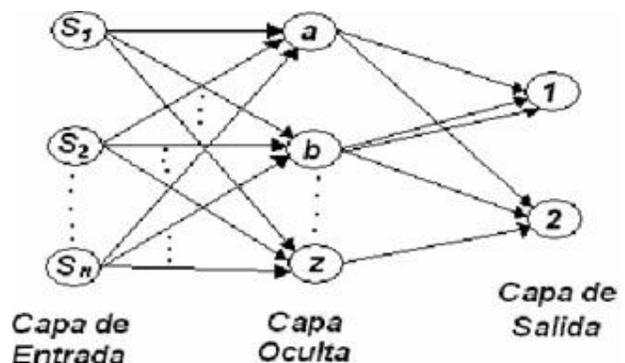


Figura 4.- Red neuronal multicapa

Modelo predictivo con RNA.

Empleando ahora en este caso un modelo con RNA predictivo, en la RN provoca la predicción de la respuesta futura de la planta, sobre un horizonte especificado Y_m . Las Y_m pasan al optimizador, el cual tiene como objetivo la minimización de un criterio de comportamiento para el cálculo de una adecuada señal de control.

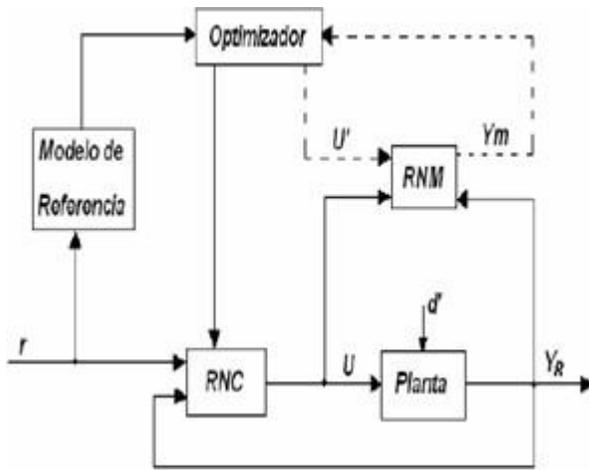


Figura 5. Modelo predictivo con RNA

Como se comprenderá para que la red resulte operativa, es necesario entrenarla, en el contexto de las redes neuronales puede definirse el aprendizaje, como el proceso por el cual se produce el ajuste de los parámetros libres de la red, a partir de un proceso de estimulación en el entorno que rodea la misma, este proceso consiste en modificar los pesos sinápticos siguiendo una cierta regla de aprendizaje, construida a partir de la optimización de una función de error o coste, que mide la eficiencia actual de la operación de la red.

El tipo de aprendizaje vendrá determinado por la forma en la que dichos parámetros son adaptados. En la mayor parte de las ocasiones el aprendizaje consiste simplemente en determinar un conjunto de pesos sinápticos que permita adaptar correctamente a la red al tipo de procesamiento deseado. Si denominamos al peso que conecta la neurona presináptica j con la postsináptica i en la iteración t , el algoritmo de aprendizaje, en función de las señales que en el instante t llegan procedentes del entorno, proporcionara el valor que da la modificación que se debe incorporar en dicho peso, el cual quedara actualizado de la forma siguiente:

$$\Delta w_{ij}(t+1) = w_{ij}(t) + \Delta w_{ij}(t) \quad (1)$$

El proceso de aprendizaje es generalmente iterativo, actualizándose los pesos de la manera anterior, una y otra vez, hasta que la red neuronal alcanza el rendimiento deseado.

Los algoritmos de aprendizaje se basan usualmente en métodos numéricos iterativos que tratan de minimizar una función de coste, lo que puede dar lugar en ocasiones a problemas de convergencia del algoritmo. Estos aspectos no pueden abordarse de un modo general, sino que deben ser estudiados para cada algoritmo concreto. En un sentido riguroso la convergencia es una manera de probar si una arquitectura determinada, junto con su regla de aprendizaje, es capaz de resolver un problema, pues el grado de error que se mide durante el proceso describe la precisión del ajuste del mapeo.

En el proceso de entrenamiento es importante distinguir entre el nivel de error alcanzado al final de la fase de entrenamiento, para el conjunto de datos que utilizamos en el propio entrenamiento y el error que la red ya entrenada, comete ante patrones no utilizados en el aprendizaje, esto nos da la idea de la capacidad de generalización de la red.

Un Perceptrón multicapa es una red con alimentación hacia delante, compuesta de varias capas de neuronas entre la entrada y la salida de la misma, esta red permite establecer regiones de decisión mucho más complejas que las de dos semiplanos, como lo hace el Perceptrón de un solo nivel. Un esquema simplificado del modelo del Perceptrón se observa en la figura 6.

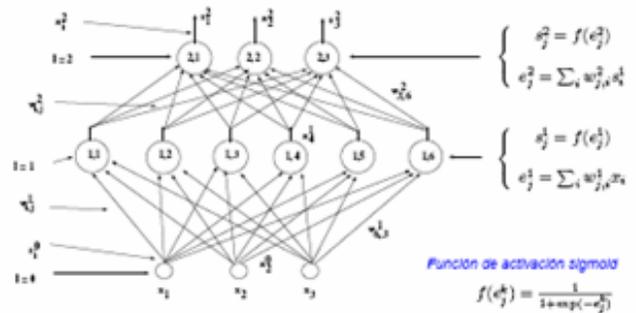


Figura 6. Perceptrón multicapa con tres entradas, tres salidas y 6 neuronas en la capa oculta.

III RESULTADOS Y DISCUSIÓN

Para la determinación del fallo es necesario realizar una serie de pasos y procedimientos, este proceso requieren laboriosidad y experiencia por parte del personal encargado de la operación del sistema, para poder ganar tiempo en la detección de las averías y evitar un número excesivo de operaciones en el sistema.

Estos eventos están caracterizados por:

- Ocurrencia de las fallas repetitivas.
- Ausencia de algoritmos, y reglas sistemáticas que describan el proceso.
- Presencia de condiciones cambiantes de operación.
- Existencia de datos históricos sobre la ocurrencia de averías y causas que la provocan.

Todo lo anterior ofrece las condiciones necesarias para el uso de una red neuronal que permita la detección o diagnóstico de fallos con una mayor eficiencia.

Teniendo en cuenta la posibilidad de aprender de las redes neuronales, se deduce que estos problemas que precisan almacenar un gran número de datos. Requieren para su solución un extenso algoritmo y aprovechan mejor la estructura de una red neuronal, que aquellas que requieren de algoritmos cortos.

Es habitual separar detección y diagnóstico de fallos, con el propósito de diferenciar entre los efectos producidos por estos en las variables medidas (detección) y la identificación y

localización de sus causas (diagnóstico). La ejecución correcta de ambas tareas reside en la utilización del conocimiento sobre la planta. Mientras que para la detección de fallos es suficiente conocer las condiciones de funcionamiento normal, para el diagnóstico a menudo se necesita de un conocimiento más profundo del proceso, incluyendo su operación en fallo.

Los métodos de trabajo con RNA están basados en la arquitectura de cada red, que son:

- El enfoque supervisado.
- El enfoque no supervisado
- El enfoque basado en modelos.
- Detección de anomalías con el modelo PRBFN.

Estos métodos centran su principal aplicación en:

1. Procesamiento de alarmas.
2. Diagnóstico de componentes.

Este trabajo pretende ejemplificar como utilizar las redes neuronales para cada enfoque a partir de las características de los sistemas de refrigeración industrial

El Enfoque Supervisado.

Las redes neuronales supervisadas son técnicas para extraer datos a partir de las relaciones de entrada-salida y para almacenar tales relaciones en ecuaciones matemáticas que pueden utilizarse en actividades de pronóstico o en la toma de decisiones. Requieren que el usuario especifique la salida deseada. La red aprende a detectar la relación entre las entradas y las salidas suministradas, mediante un proceso iterativo y adaptativo. Una vez que la red se ha entrenado, se puede utilizar con datos que nunca haya visto o puede ser embebida en un programa para el apoyo a las decisiones.

Siendo este el primer método a analizar y más sencillo que los demás para detectar anomalías, representado como una caja negra con un número de entradas llamadas medidas o alarmas y un número de salidas, estas pueden ser para funcionamiento normal o para anomalías (Figura 7). El diagnóstico puede ser considerado como una función que liga el espacio de medidas con el espacio de salidas o anomalías.

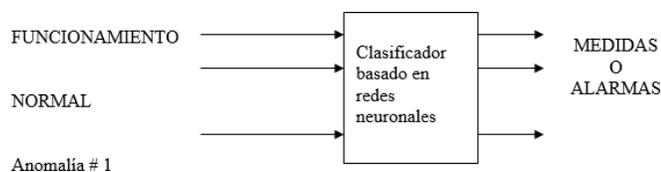


Figura 7. Enfoque supervisado

Procedimiento:

Paso 1: Diseño de la representación de E/S

- Selección del vector de características (entradas).
- Lista de posibles anomalías (salidas)

Paso 2: Preparación de un conjunto de datos y verificación de los conjuntos de entrenamiento y test.

- Todas las anomalías consideradas han de quedar reflejadas en el conjunto de datos.
- Cuando no existe una base de datos de fallo completa se recurre a las técnicas de simulación.

Paso 3: Ajuste de la Red Neuronal.

Paso 4: Validación

Una red tipo Perceptrón de una sola capa es una buena solución a un problema que involucre patrones linealmente separables, en el caso de contar con patrones que no son linealmente separables se tiene la alternativa de utilizar una red Perceptrón Multicapas o cambiar definitivamente de red, nótese que una red Perceptrón Multicapas puede solucionar el problema de separabilidad lineal a medida que aumenta el número de capas de la red

La red BP puede emplearse en tareas de ajuste funcional (predicción, series temporales, modelización, diagnóstico), y también para clasificación. Esta es la red neuronal por excelencia, empleada en más del setenta por ciento de los casos. La red neuronal se ajustará de tal manera que a medida que se entrena, las neuronas de las capas intermedias se organizan a sí mismas de tal modo que éstas aprenden a reconocer distintas características del espacio total de entrada. Después del entrenamiento, cuando se les presente un patrón arbitrario de entrada que contenga ruido o que esté incompleto, las neuronas de la capa oculta de la red responderán con una salida activa si la nueva entrada contiene un patrón que se asemeje a aquella característica que las neuronas individuales hayan aprendido a reconocer durante su entrenamiento. Y a la inversa, las unidades de las capas ocultas tienen una tendencia a inhibir su salida si el patrón de entrada no contiene la característica para reconocer para la cual han sido entrenadas.

La capacidad de generalización de las redes neuronales juega un papel importante cuando las posibles combinaciones de patrones de entrada son tantas que resultaría imposible especificarle a un dispositivo que hacer en cada caso, puesto que la red se entrena con un número de patrones representativo y no con la totalidad de ellos, ahorrando tiempo de computo en la solución del problema.

En las aplicaciones desarrolladas con redes neuronales juega un papel importante la tolerancia a fallas que las caracteriza, pues en caso de fallar uno o varios sensores, la red siempre producirá una salida que en la mayoría de los casos es la más acertada, debido a que la red después de un proceso de aprendizaje exitoso esta en capacidad de generalizar el comportamiento del sistema.

El Enfoque basado en modelos

El enfoque basado en modelos no es más que mediante la utilización de un modelo de red neuronal detectar el error o falla cometido en algún parámetro de la línea y a través de un sistema de decisión enviar una señal de diagnóstico ya sea a un computador o a una protección encargada de resolver la situación. Para esta tarea se utiliza un esquema que responda ante varias señales de entrada provenientes de la red (figura 8).

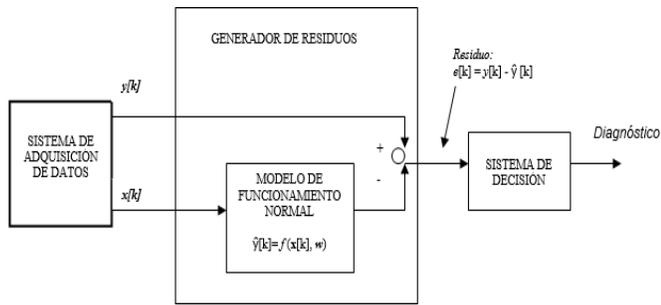


Figura 8. Enfoque basado en modelos

El Sistema de Adquisición de Datos es un autómata programable registra los parámetros del sistema serán analizados por la red neuronal; $y[k]$ es el vector de salidas del Sistema de Adquisición de Datos que contiene los errores de los parámetros registrados; $x[k]$ es el vector que contiene los datos procedentes del sistema de refrigeración analizado que serán las entradas al Modelo de Funcionamiento Normal que no es más que la red neuronal encargada de hacer el procesamiento de la información, él solo debe considerar, como su nombre lo indica, situaciones de funcionamiento normal; no requiere conocimiento de las situaciones de anomalías. Por lo general esta red suele ser de tipo Perceptrón Multicapas o en algunos casos Mapas autoorganizados.

Se utiliza la red tipo Perceptrón cuando el proceso requiere de la corrección de errores a través de la retropropagación del mismo.

Una de las mayores ventajas de las redes multicapas, y en especial de la red Backpropagation, es que pueden aproximar cualquier función si se escoge una adecuada configuración para la red y un adecuado número de neuronas en la capa oculta, que depende de la experiencia del desarrollador de la red. La red Perceptrón Multicapas es un excelente aproximador de funciones, aunque es imposible determinar una configuración exacta de la red para cada aplicación.

Esta red neuronal será la encargada de obtener, en funcionamiento normal, un vector de salida calculado, denominado $\hat{y}[k]$ que está en función de las entradas $x[k]$ y de los pesos w . Este vector contendrá los errores que se presentan en los parámetros en su funcionamiento normal, que serán comparados con el vector de salida $y[k]$ proveniente del sistema de adquisición de datos. Este proceso recibe el nombre de Generación de Residuos, representado por el vector $e[k]$ denominado Residuo.

Después de generar el residuo, se debe utilizar un mecanismo de decisión para determinar la ocurrencia y localización del fallo. Tradicionalmente, el módulo de decisión se ha implementado mediante lógica de umbrales utilizando umbrales fijos o adaptativos o variables o métodos basados en tests estadísticos. La principal tarea del módulo de decisión es clasificar los residuos en un número de patrones distinguibles correspondientes a diferentes situaciones de fallo. Así, el

módulo de decisión puede basarse en el principio de reconocimiento de patrones. El reconocimiento de patrones implica ciertas acciones iniciales basadas en la observación de los datos de entrada.

A la entrada que representa un patrón se le conoce como vector de medida o el vector característico. La función obtenida mediante un sistema de reconocimiento de patrones es el encuadre del vector característico de entrada en una de las varias clases de decisión.

Sistema de detección de fallos.

Los fallos constituyen todo cambio en el comportamiento de algún componente del sistema, desviación no permitida de algunas de sus propiedades o parámetros característicos, de manera que éste ya no puede satisfacer la función para la cual ha sido diseñado.

Los sistemas de control automático son susceptibles a los fallos, por ello existe una creciente necesidad e interés en desarrollar sistemas de control que puedan operar de forma aceptable, incluso después de la aparición de un fallo y que sean capaces de parar el proceso antes de que se produzca el daño en dimensiones catastróficas.

En diagnósticos de fallos, estas clases de decisión son los diferentes tipos (o localización) de fallos que ocurren en el sistema. Una de las ventajas de las redes neuronales es su capacidad para particionar el espacio de patrones para problemas de clasificación. Así, se puede utilizar una red neuronal como clasificador (o reconocedor de patrones) para particionar patrones de residuo y activar señales de alarma. Puede por lo tanto detectar y aislar fallos. En el entrenamiento de redes neuronales para clasificar fallos se utilizan valores de 0.1 a 0.9 en los nodos de salida para indicar la ausencia y presencia de fallo respectivamente. En la aplicación a diagnóstico de fallos, valores superiores a 0.5 en los nodos de salida indican un fallo. Si se conocen los patrones de fallo que ocurren ante fallos específicos, esta información podría almacenarse en la red neuronal eligiendo su conjunto de entrenamiento en concordancia con los fallos conocidos.

Este enfoque presenta un número de pasos que conforman el procedimiento a seguir para su utilización.

Procedimiento:

Paso 1: Diseño de la representación E/S.

- Selección de las variables de salida que han de ser estimadas.
- Selección de las variables de entrada: identificación de sistemas.

Paso 2: Preparación de un conjunto de datos y generación de los conjuntos de

entrenamiento y test.

- Solo han de considerarse situaciones de funcionamiento normal.
- Este enfoque no requiere conocimiento del comportamiento de los componentes en estado de anomalía.

Paso 3: Aprendizaje.

- Ajuste de los modelos de funcionamiento normal (estructura y parámetros).
- Descripción estadística de los residuos en condiciones de funcionamiento normal.

Paso 4: Validación.

- El sistema se valida bajo condiciones de funcionamiento normal y anómalo para evaluar su sensibilidad. El nuevo equipamiento adquirido para la automática de del frigorífico nos brinda la posibilidad de que en su operación bacia los datos adquiridos del los sensores en ficheros Excel y como las redes neuronales pueden ser trabajadas con el Matlab, se pueden interactuar con ellos y de esta forma se tienen los vectores de entrada $x[k]$ y $X[k]$ para el generador de residuos para la obtención $e[k] = y[k] - \hat{y}[k]$ (Residuo) para pasar a la etapa del sistema de decisión y luego al diagnostico par con esto la relazar la posible eliminación de cualquier tipo de fallo desde su etapa evolutiva ver figura 9

A la hora de hacer el diseño de la representación E/S se tienen en cuenta parámetros como las presiones en diferentes puntos claves, corriente de equipos principales, temperaturas y el esquema de trabajo que se encuentra en el momento del análisis así como las condiciones de trabajo normales para cada una de estas variables de entrada ($X[k]$) conformándose de esta forma el vector de salida que corresponde al de entrada correspondiente y a su vez el modelo de trabajo normal $\hat{y}[k] = f(x[k], w)$ para obtener $e[k]$ después de su comparación con $y[k]$ que es el vector de salidas del Sistema de Adquisición de Datos que contiene los errores de los parámetros registrados ver la figura 9.

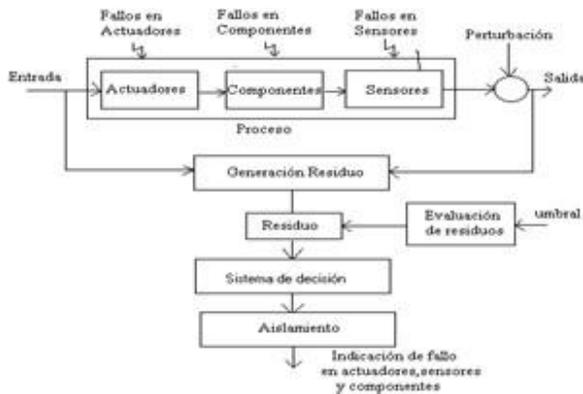


Figura 9. Sistema de detección y aislamiento de fallos (FDI)

Se observa que el problema de la detección y diagnóstico de fallos consta de 4 fases:

1. Generación de residuos.
2. Evaluación de residuos.
3. Sistema de decisión.
4. Aislamiento de fallo

Cada una de estas fases es dedicada a actividades puntuales de forma tal que posibilite obtener el mejor diseño posible, es así que:

1. Se genera la discrepancia entre el sistema real y un modelo sin fallo del mismo.
2. Se evalúa si esta discrepancia o residuo generado es significativo respecto a un umbral.
3. Es donde se debe decidir cuando existe o no un fallo.
4. Donde deberá disponerse de algún mecanismo que nos indique la localización del fallo físico.

A partir de una secuencia de entradas U y salidas Y obtenidas de los sensores instalados en el proceso a monitorear, se trata de verificar la consistencia con el comportamiento modelado, (ecuaciones 2 y 3):

$$x(t) = g(x(t), u(t), \theta) \quad (2)$$

$$y(t) = h(x(t), u(t), \theta) \quad (3)$$

Donde:

$X \in R^{n_x}$, $U \in R^{n_u}$ y $Y \in R^{n_y}$ son los vectores de estado, entrada y salida de dimensión n_x , n_u y n_y , respectivamente; g y h son las funciones de espacio de estado y medida respectivamente; θ este es el vector de parámetros de dimensión (P) . La detección de una inconsistencia es indicativa en la presencia de un fallo.

Detección de fallos basada en modelos cuantitativos

En el caso de utilizar modelos cuantitativos, una forma de verificar la consistencia entre el modelo y las medidas de las entradas/salidas es generar, a partir de las mismas (u, y) y del modelo, una estimación de las salidas \hat{y} . La consistencia entre el sistema real y el modelado se evalúa a cada instante de tiempo mediante la diferencia:

$$r(t) = y(t) - \hat{y}(t) \quad (4)$$

Conocida como residuo, o bien, a partir de relación más compleja que involucra a las entradas $u(k)$ y salidas medidas $y(k)$ así como los parámetros del sistema denominada relación de redundancia analítica:

$$\phi(t) = f(u(t), y(t), \theta) \quad (5)$$

Las técnicas más utilizadas para generar residuos mediante modelos analíticos son:

- 1- Ecuaciones de paridad.
- 2- Observadores.

Mientras que las técnicas de generación de relaciones de redundancia analítica más conocidas son las basadas en:

- 1- Espacio de paridad.
- 2- Análisis estructural.

Aislamiento del fallo

Una vez realizada la detección, es necesario realizar un análisis de la causa que ha provocado la no consistencia, es

decir el fallo. Este análisis puede realizarse de 2 formas

diferentes, ya sea utilizando:

- Matriz de firma de fallo (enfoque FDI).
- El diagnóstico basado en consistencia (enfoque DX).

Ambas formas tienen en común que parten de un conjunto de indicadores de consistencia que se corresponde con las denominadas relaciones de redundancia analítica ARR. Dichas relaciones se obtienen a partir de las relaciones elementales de los componentes del sistema a base de eliminar las variables intermedias no medidas, por lo tanto, quedan vinculadas a los posibles fallos que pueden presentar los componentes utilizados para generarlas.

Aislamiento del fallo según FDI

En el enfoque FDI, a partir del conjunto de residuos se define la matriz de firmas de fallo teórica. Esta matriz de firmas de fallo teórica contiene de forma codificada la dependencia de un determinado fallo (columna de la matriz) con cada residuo (fila de la matriz). Un elemento Σ_{ij} de esta matriz es igual a 1 si el fallo de la columna j influye en el residuo de la fila i , en caso contrario será 0, partiendo de la hipótesis de fallo simple.

En el caso de que se consideren fallos múltiples, el número de columnas de la matriz de signatura de fallos teórica debería aumentarse hasta considerar todas las posibles combinaciones. En tiempo real, cada uno de los residuos $r_i(k)$ considerado será evaluado respecto a su umbral τ_i . El resultado proporciona un conjunto de firmas de fallo observadas del sistema:

$$s(k) = [s_1(k), \dots, s_n(k)] \tag{6}$$

Donde:

$$s_i(k) = \begin{cases} 0 & \text{si } r_i(k) < \tau_i \\ 1 & \text{si } r_i(k) \geq \tau_i \end{cases}$$

Entonces, el aislamiento del fallo consistirá en encontrar cuál de las firmas de fallo de la matriz de signatura de fallos se aproxima más a la firma $s(k)$ encontrada experimentalmente. El grado de aproximación se mide calculando alguna distancia entre las dos. En la práctica, las más utilizadas son la distancia Euclidiana o la distancia de Hamming.

Utilizando la distancia de Hamming, el procedimiento de aislamiento daría un vector de distancias de cada firma de fallo:

$$d(k) = [d_1(k), \dots, d_n(k)] \tag{7}$$

$$d_j(k) = \sum_{i=1}^n (\sum_{ij} \oplus s_i(k)) \tag{8}$$

Donde:

\oplus es el operador lógico XOR. La firma de fallo teórico que presentara la distancia menor indicaría cuál es el posible fallo del sistema.

Aplicación de las RNA al método FDI

Ajustando el método de Newton, obtenemos el algoritmo de Levenberg Marquardt

$$x_{k+1} = x_k - [J^T(x_k)J(x_k) + \mu_k I]^{-1} J^T(x_k)v(x_k) \tag{9}$$

O

$$\Delta x_k = -[J^T(x_k)J(x_k) + \mu_k I]^{-1} J^T(x_k)v(x_k) \tag{10}$$

La nueva constante determina la tendencia del algoritmo, cuando se incrementa, este algoritmo se aproxima al algoritmo de pasos descendientes para tasas de aprendizaje muy pequeñas; cuando se decreta este algoritmo se convierte en el método de Gauss – Newton

El algoritmo comienza con un valor pequeño para μ_k por lo general 0.01, si en ese paso no se alcanza el valor para $e(x)$ entonces el paso es repetido con multiplicado por un factor >1 . Si se ha escogido un valor pequeño de paso en la dirección de paso descendiente, $e(x)$ debería decrecer. Si un paso produce un pequeño valor para $e(x)$, entonces el algoritmo tiende al método de Gauss - Newton, el que se supone garantiza una rápida convergencia. Este algoritmo genera un compromiso entre la velocidad del método de Gauss-Newton y la garantía de convergencia del método de paso descendiente.

Los elementos de la matriz Jacobiana necesarios en el algoritmo de Levenberg-Marquardt son de este estilo:

$$[J]_{h,l} = \frac{\partial e_{k,q}}{\partial x_l} \tag{11}$$

Donde x es el vector de parámetros de la red, que tiene la siguiente forma:

$$x^T = [x_1, x_2, \dots, x_n] = [w_{1,1}^1, w_{1,2}^1, \dots, w_{s^1,R}^1, b_1^1, \dots, b_{s^1}^1] \tag{12}$$

Para utilizar este algoritmo en las aplicaciones para redes multicapas, se redefinirá el término sensibilidad de forma que sea más simple hallarlo en cada iteración.

$$s_{i,h}^m \equiv \frac{\partial e_{k,q}}{\partial n_{i,q}^m} \quad (13)$$

Donde $h = (q-1)S^M + k$

Con la sensibilidad definida de esta manera, los términos de la matriz Jacobiana pueden ser calculados más fácilmente:

$$[J]_{h,j} = \frac{\partial e_{k,q}}{\partial w_{i,j}^m} = \frac{\partial e_{k,q}}{\partial n_{i,q}^m} * \frac{\partial n_{i,q}^m}{\partial w_{i,j}^m} = s_{i,h}^m * \frac{\partial n_{i,q}^m}{\partial w_{i,j}^m} = s_{i,h}^m * a_{j,q}^{m-1} \quad (14)$$

y para las ganancias:

$$[J]_{h,i} = \frac{\partial e_{k,q}}{\partial b_i^m} = \frac{\partial e_{k,q}}{\partial n_{i,q}^m} * \frac{\partial n_{i,q}^m}{\partial b_i^m} = s_{i,h}^m * \frac{\partial n_{i,q}^m}{\partial b_i^m} = s_{i,h}^m \quad (15)$$

De esta forma, cuando la entrada pQ ha sido aplicada a la red y su correspondiente salida aMQ ha sido computada, el algoritmo Backpropagation de Levenberg-Marquardt es inicializado con:

$$S_q^M = -f^M(n_q^M) \quad (16)$$

Cada columna de la matriz SMQ debe ser propagada inversamente a través de la red para producir una fila de la matriz Jacobiana. Las columnas pueden también ser propagadas conjuntamente de la siguiente manera:

$$S_q^m = f^m(n_q^m)(W^{m+1})^T S_q^{m+1} \quad (17)$$

Las matrices sensibilidad total para cada capa en el algoritmo de Levenberg-Marquardt son formadas por la extensión de las matrices computadas para cada entrada:

$$S^m = [S_1^m][S_2^m] \dots [S_Q^m] \quad (18)$$

Para cada nueva entrada que es presentada a la red, los vectores de sensibilidad son propagados hacia atrás, esto se debe a que se ha calculado cada error en forma individual, en lugar de derivar la suma al cuadrado de los errores. Para cada entrada aplicada a la red habrá SM errores, uno por cada elemento de salida de la red y por cada error se generará una fila de la matriz Jacobiana.

El comportamiento de este algoritmo se visualiza en la figura 10, la cual muestra la trayectoria de convergencia del método empleado:

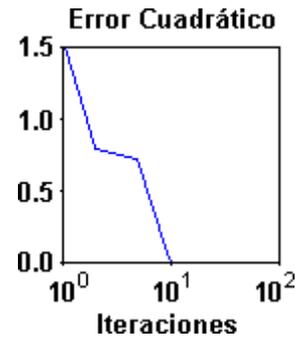


Figura 10. Trayectoria del algoritmo Levenberg-Marquardt

Como puede verse, este algoritmo converge en menos iteraciones que cualquier método discutido anteriormente, por supuesto requiere mucha más computación por iteración, debido a que implica el cálculo de matrices inversas. A pesar de su gran esfuerzo computacional sigue siendo el algoritmo de entrenamiento más rápido para redes neuronales cuando se trabaja con un moderado número de parámetros en la red

Recolección y análisis de los datos e interpretación de los resultados

Como parte de la investigación se trabajó en el tema de los puntos calientes, correspondientes a la subestación Portoviejo 2, especialmente sobre la situación de los alimentadores 21, 22 y 23. Los objetivos se centraron en obtener información relacionada con la calidad del servicio eléctrico y la influencia que en ello tienen los puntos calientes, definiendo la importancia de su detección anticipada, por lo que se pudo comprobar lo siguiente:

1. Líneas eléctricas alimentadores ya tienen varios años en operación, presentando deficiencias en el apriete de partes de uniones;
2. Los efectos de la contaminación ambiental, que ha propiciado la aceleración de la corrosión en uniones de materiales de diferentes características metálicas (par galvánico);
3. Sobrecarga de las líneas por incremento incontrolado de la demanda, que propicia el sobrecalentamiento de las líneas y los transformadores.
4. Actualmente las inspecciones se realizan priorizando los alimentadores donde se reportan fallos, pudiendo elaborar un informe técnico, que permite ajustar los planes de mantenimiento en función de corregir las debilidades del sistema, pudiendo anticipar las fallas y corregir los problemas.

Para la confección de la redes neuronales para el Sistema expert, se trabajó como entradas las clasificadas por los valores que aparecen en la siguiente table, con su correspondiente

salida, que nos emitirá el tipo de mantenimiento a efectuar según el interval adaptivo que se ha ubicado como umbral en el análisis de cada uno de los casos:

Tabla 1. Ponderación atendiendo al riesgo eléctrico

Variables	P.P.C	Riesgo Eléctrico	Ponderación n
G.D.C.C.	50,00		
D.L	%	100,00%	75,00%
	50,00		
G.D.C.C.E	%	50,00%	50,00%
	50,00		
G.R	%	10,00%	30,00%
	50,00		
C.C	%	30,00%	40,00%
	50,00		
E.E.L	%	30,00%	40,00%
	50,00		
A.C.A	%	40,00%	45,00%
	50,00		
C.Q	%	100,00%	75,00%
	50,00		
A.C	%	30,00%	40,00%
	50,00		
M.L	%	10,00%	30,00%

Tabla 2. Clasificación del mantenimiento a partir del umbral

Indicador umbral	de	Tipo de Mantenimiento	de
0-0.49		Preventivo	
0.5-0.69		Predictivo	
0.7-0.79		Proactivo	
0.8-1.0		Correctivo	

Con estas consideraciones se propone la estructura del modelo de red neuronal a emplear para la detección y aislamiento de los fallos, basandonos en el análisis de los puntos calientes en las líneas de transmission que hn sido objeto de estudio. Se emplea entonces mediante técnicas de reconocimiento de patrones como se muestra en la figura siguiente.

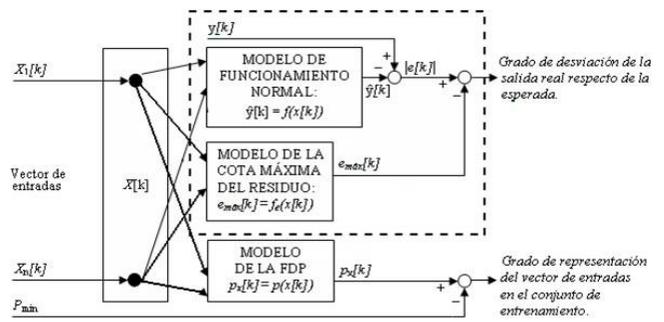


Figura 11. Modelo para la detección de fallos mediante modelo de funcionamiento normal modificado para el uso de la técnica de reconocimiento de patrones

La idea propuesta consiste en alimentar el modelo con patrones representativos de todas las condiciones de trabajo del sistema para obtener a la salida, directamente, una estimación de su estado, es decir, si está o no en fallo.

Alimentando la red con el caso del uso del modelo de funcionamiento normal, se garantiza que durante el entrenamiento, mediante un proceso de asociación libre de las variables de entrada, se obtenga el modelo que detecta mejor el fallo.

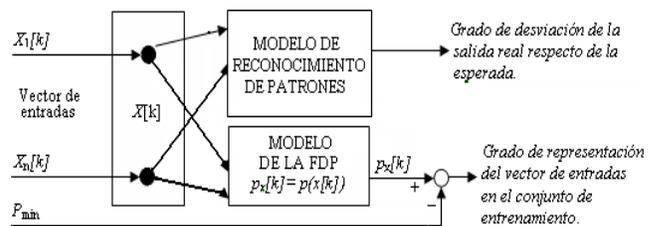


Figura 12. Modelo para la detección de fallos utilizando técnicas de reconocimiento de patrones.

Luego con esas estructuras de red se podrá proponer el tipo de mantenimiento que debe efectuarse, así como predecir el rango de ocurrencia de fallos en cada sector analizado, entrenando la red con la dupla de vectores entradas – salidas que le corresponden a cada uno de los casos según la base de datos capturada con anterioridad.

IV. CONCLUSIONES

Se logró realizar la inspección técnica para el descubrimiento de puntos calientes en los alimentadores 21, 22 y 23 de la subestación Portoviejo 2, logrando predecir anticipadamente las averías en función de garantizar el correcto funcionamiento del sistema.

Se realizó el levantamiento de información previa en las líneas eléctricas de los alimentadores 21,22, y 23 de la subestación Portoviejo 2, mediante la técnica tradicional de inspección visual y con el uso de la cámara fotográfica para predecir puntos calientes.

Se determinó la existencia de 8 puntos calientes en función del parámetro de temperatura establecido por CNEL EP Manabí, pudiendo conocer la magnitud de la temperatura y el cálculo de la energía disipada en estos, gracias a la utilización de la cámara termográfica.

Se logró realizar la identificación de posibles averías que se pudieran presentar en las estructuras técnicas de los alimentadores inspeccionados, con la respectiva elaboración de un análisis exhaustivo que contiene los resultados obtenidos y que permite predecir las futuras averías, con el objetivo de mantener la continuidad del suministro eléctrico a los usuarios.

Con la información obtenida fue conformado directamente el Sistema expert basado en redes neuronales para lograr la predicción de los fallos, así como el tipo de mantenimiento que granatiza la seguridad de suministro en la CNEL EP Manabí.

REFERENCIAS Y BIBLIOGRAFÍA

1. Mujal R. Ramón. (2011). Tecnología eléctrica. 2º Edición ampliada y revisada. http://ocw.upc.edu/sites/all/modules/ocw/estadistiques/download.php?file=27854/2011/1/53020/tecnologia_elctrica-2596.pdf
2. Joseph Seymour y Terry Horsley. (2015). Los siete tipos de problemas en el suministro eléctrico. Informe interno. https://eva.fing.edu.uy/pluginfile.php/90432/mod_resource/content/1/Siete_tipos_de_problemas_en_el_suministro_electrico.pdf.
3. Chaparro Consuelo y colectivo de autores. (2010). La Eficiencia Energética en el Currículum Escolar de Educación Técnica Profesional. Departamento de Educación Ambiental y Participación Ciudadana. Comisión Nacional de Medio Ambiente. Ministerio de Medio Ambiente Chile.
4. SDD. (2015) Comisión Federal de electricidad. Coordinación de Distribución. Capítulo XVII: Detección y medición de puntos calientes.
5. Alaba, I. (2013). Guía de termografía para mantenimiento predictivo "flir". Consultado el 5 de diciembre de 2016. Disponible en: <http://www.flir.es/home/>
6. Poyato Roberto. (2014). Departamento de soporte técnico de Fluke Ibérica.
7. FLUKE. Termografía en sistemas eléctricos en planta. Consultado el 5 de diciembre de 2016. Disponible en: <http://www.fluke.com/fluke/eses/soluciones/cameras-termograficas/termografia-en-sistemas-electricos-en-planta>.
8. Franco T Serbio B. (2014). TESIS (Contaminación por salinidad en líneas de transmisión cercanas a la costa).
9. Crespo Quintero, I. E. (2010). Desarrollo de un modelo para la localización de fallas en UNAL, <http://www.bdigital.unal.edu.co/2028/1/71795342.20101.pdf>.
10. FLIR (2011). Grupo Álava Ingenieros. Guía informativa del uso de cámaras termográficas en aplicaciones industriales. <http://www.mra.pt/repositorio/6769/pdf/3505/2/guia-de-termografia-para-mantenimiento-predictivo.pdf>.
11. Grijalva D Iván. (2013). Sistemas autónomos de análisis y detección de puntos calientes en cuadros eléctricos. Proyecto de fin de carrera. Universidad de la Rioja. España.
12. Gallo Omar D y Colectivo de autores. (2016). Ensayo de determinación de puntos. Calientes en estatores trifásico
13. Jiménez Obed, Cantu Vicente y Conde Arturo. (2006). Líneas de Transmisión y Distribución de energía eléctrica. Departamento de iluminación y alta tensión. Ciudad Universitaria, San Nicolás de los Garza Nuevo León.
14. ENDESA. (2016). La red eléctrica. Consultado el 7 de septiembre de 2016. Disponible en: http://www.endesaeduca.com/Endesa_educa/recursos-interactivos/el-transporte-de-electricidad/xv.-la-red-electrica.
15. Ramírez Samuel. (2004). Redes de Distribución de Energía. Universidad Nacional de Colombia. Tercera Edición. Manizales, I.S.B.N 958-9322-86-7.
16. Pascual Álvaro. (2016). Sistemas de transporte y distribución de las líneas eléctricas. Consultado el 7 de septiembre de 2016. Disponible en: <http://www.monografias.com/trabajos101/sistemas-transporte-y-distribucion-lineas-electricas/sistemas-transporte-y-distribucion-lineas-electricas.shtml>.