

CAPITULO I

INTRODUCCION

1.1 Motivación

La red eléctrica de México, aún cuando ha tenido un crecimiento considerable en los últimos años, sigue siendo un sistema en el que predominan las características que distinguen a los sistemas débiles, como son: Capacidades de cortocircuito reducidas, grandes distancias (geográficas y eléctricas) entre centros de generación y consumo, restricciones en la transmisión de energía, etc.

Los problemas que surgen en la operación de este tipo de redes son muy particulares y no es común que los especialistas de países desarrollados los aborden con la profundidad requerida. Es vital para los encargados de la planeación y operación de sistemas eléctricos débiles enfrentarse con los retos que plantea la solución de estos problemas, que están relacionados de manera estrecha con el comportamiento dinámico.

En la evaluación de la estabilidad transitoria en línea, tema que se aborda en esta tesis, intervienen diversos factores que es necesario analizar para comprender el problema y para proponer alternativas de solución adecuadas.

La estabilidad transitoria en los sistemas eléctricos de potencia (SEP) es un tema que ha sido estudiado ampliamente y se acepta que la simulación en el dominio del tiempo proporciona la flexibilidad requerida en el modelado de elementos así como

resultados confiables. Sin embargo, debido al crecimiento natural de las redes eléctricas se ha observado una necesidad cada vez mayor de incrementar la velocidad con que se efectúan los estudios de estabilidad, tanto para la planeación de la expansión del sistema a largo plazo, como para la planeación de la operación y durante la operación en tiempo real [39]. Cada campo de aplicación tiene necesidades propias, que requieren diferentes enfoques. Las alternativas actualmente investigadas van desde la utilización de nuevos y más poderosos equipos de cómputo, hasta las opciones algorítmicas basadas en las técnicas de la función de la energía o el reconocimiento de patrones y equivalentes dinámicos.

Este trabajo se concentra en los aspectos que se relacionan con la operación en tiempo real del sistema eléctrico, donde además de la rapidez con que se requieren los resultados de los estudios dinámicos, es necesario extraer de ellos conclusiones que puedan ser de utilidad inmediata al usuario final de la herramienta: El personal de operación de los centros de control.

Desde los centros de control se dictan las operaciones de maniobra, se asigna la generación de unidades y, en condiciones de emergencia, se ordenan o se efectúan una secuencia de acciones de control que tienden a restaurar las condiciones normales de la red. Conforme aumenta el tamaño del sistema eléctrico crece el número de variables a considerar para tomar una decisión y ésta se dificulta aún más en condiciones de disturbio.

Las herramientas que auxilien al personal de operación deberían incorporar cierta "inteligencia", que las haga capaces de sintetizar la información más significativa a partir del gran volumen de información que se recibe en los centros de control, tanto en condiciones de operación normales, para la prevención de disturbios, como en condiciones de emergencia, para filtrar la información intrascendente y auxiliar en la restauración de la red eléctrica.

Desde el punto de vista de un operador del sistema sería deseable contar en el centro de control con una herramienta con la que se pudiera obtener una evaluación de la condición de operación en la red, tanto para el estado estable, como para el o los posibles estados transitorios. Los sistemas de adquisición y validación de información permiten obtener un panorama general del estado estable del sistema. Para conseguir una percepción similar, en el segundo caso, es necesaria una herramienta capaz de responder rápidamente a preguntas relacionadas con el desarrollo transitorio de los eventos de interés, considerando la condición de operación actual; preguntas del tipo siguiente:

¿Cual es el nivel de seguridad transitoria en este momento?

¿El sistema se mantiene estable si en este momento ocurre la falla A?
...o la falla B? ...o la falla C? etc.

¿Se mantendrá la estabilidad en media hora, cuando se presente la demanda máxima si ocurre la falla A? ...o la falla B? ... o la falla C? etc.

¿Perderán sincronismo las máquinas de la planta P, si sale de operación la línea de transmisión LT1 y ocurre la falla A? ...o la falla B? ...o la falla C? etc.

Si se presenta la pérdida de estabilidad en alguno de los casos anteriores, ¿Que se puede hacer para evitarlo? ¿Es suficiente disminuir la generación de las unidades de la planta P para lograr mejorar los índices de estabilidad? ¿Cual es el monto mínimo de generación que se debe disminuir? ¿Será necesario activar algún tipo de control suplementario para asegurar que ante la pérdida de estabilidad no se presente un colapso generalizado?

El número de alternativas que se pueden plantear crece con la complejidad del sistema de potencia y en el diseño práctico de cualquier herramienta se debe considerar

una dimensión máxima de posibilidades. Es posible acotar el número de preguntas definiendo los casos de interés, estableciendo las fallas y condiciones de operación más probables o las más críticas, considerando estudios analíticos previos y por supuesto, la experiencia práctica de los operadores del sistema.

En esta tesis se plantea la posibilidad de que la base de la herramienta que se menciona sea la aplicación de las técnicas de redes de neuronas artificiales a la información generada por un conjunto de estudios de estabilidad, mediante el diseño de una red de neuronas artificiales que sea capaz de responder a las preguntas que se enunciaron, con un alto grado de certidumbre.

1.2 Análisis de Seguridad en Estado Transitorio

La definición común de seguridad se establece como ausencia de riesgo o peligro. En la operación de un sistema de potencia siempre existen riesgos, por lo que la seguridad se da como un índice relativo a un cierto riesgo. En este caso, al riesgo de que se interrumpa la continuidad en el servicio.

La seguridad es una condición instantánea y por lo tanto variante en el tiempo, que refleja la robustez de un sistema de potencia con respecto a un conjunto de disturbios especificados. Se evalúa por medio de un índice cualitativo o cuantitativo determinado en base a un procedimiento de clasificación arbitrario, previamente acordado. La seguridad se supervisa a través de la medición de un grupo de variables del sistema y del medio ambiente, que la afectan.

El análisis de seguridad consiste en la evaluación del índice de seguridad del sistema en su estado actual, basado en un grupo de datos muestreados por algún sistema de adquisición y validados con los criterios apropiados.

La determinación del nivel de seguridad tanto en estado estable como transitorio, es importante para alertar a los operadores acerca de posibles fallas críticas, y permite realizar las acciones de control convenientes. Una definición de seguridad [22] se establece como la prevención de disparos en cascada, cuando el sistema está sujeto a disturbios severos. Para ayudar a que no ocurran disparos en cascada es necesario que el sistema se diseñe y opere cumpliendo con las siguientes condiciones:

- a) Que no existan sobrecargas en equipo ni en líneas de transmisión.
- b) Que todos los nodos conserven su voltaje dentro de los límites permitidos.
- c) Si ocurre cualquiera de una serie de disturbios especificados, se asegure que se llegará a operar en una nueva condición donde se cumplan a) y b).

Las dos primeras condiciones requieren de un análisis de seguridad en estado estable, para la tercera será necesario llevar a cabo un análisis transitorio.

Existen diferentes métodos algorítmicos que ofrecen índices de seguridad en estado estable, pero que no proporcionan información con respecto al comportamiento dinámico del sistema. El análisis de seguridad en estado estable da por hecho que después de un disturbio el sistema es capaz de llegar a un nuevo punto de operación estable, limitándose a verificar que en la nueva condición no se violen las restricciones operativas de voltajes nodales y flujos en líneas de transmisión.

El análisis dinámico permite determinar lo que sucede en la transición hacia ese nuevo punto, y a la vez definir si es un punto de operación factible. Las posibilidades de llegar a estado estable disminuyen si la contingencia es crítica, o si la red de transmisión es débil.

Para el análisis fuera de línea, del comportamiento dinámico de un sistema eléctrico para la planeación de la operación, se han utilizado programas digitales de estabilidad transitoria, con los que se simula la ocurrencia de disturbios como una

secuencia de eventos en el tiempo, y los resultados se traducen en guías operativas o instrucciones específicas que los operadores de la red deben acatar para asegurar el margen de seguridad establecido. Por lo general, este tipo de análisis se limita a las contingencias más críticas, considerando condiciones de demanda típicas y para la topología más probable de la red, debido al corto tiempo disponible para su realización.

El análisis de seguridad transitoria en línea exige una mayor velocidad de procesamiento de los algoritmos, que cuando se utiliza con propósitos de planeación, requiere además una mayor flexibilidad de las herramientas de simulación para adaptarse rápidamente a las cambiantes condiciones operativas. La herramienta básica del análisis de seguridad transitoria es el estudio de estabilidad. Enseguida se mencionan las características más relevantes de las diferentes alternativas que se han planteado para la realización de estudios rápidos de estabilidad transitoria.

1.2.1 Supercomputadoras vectoriales

El uso de supercomputadoras es una de las opciones de solución que afrontan el problema desde el punto de vista de que se deben aprovechar las características del nuevo equipo de cómputo disponible, sin cambiar sustancialmente la base conceptual de los algoritmos de solución en el tiempo.

La arquitectura especial de este tipo de máquinas permite gran velocidad de ejecución [33]. Esto se logra al dividir una operación compleja en n suboperaciones simples (etapas), que se deben ejecutar de manera secuencial para obtener una solución, y a la posibilidad de ejecutar las n suboperaciones al mismo tiempo (procesamiento en paralelo). La velocidad de ejecución se incrementa proporcionalmente al número de etapas utilizadas, de manera que es teóricamente posible obtener velocidades superiores a 100 MFLOPS (millones de operaciones de punto flotante por segundo), cuando se utilizan diez etapas. Entre las desventajas se tiene el alto costo, la necesidad de

desarrollar algoritmos especiales para hacer un uso eficiente de la capacidad de la máquina de operar sobre grandes vectores y matrices densas [37,38], además de que no son apropiadas para el manejo eficiente de bases de datos, lo que resulta indispensable para una aplicación en línea. Por otra parte, su costo se podría compensar si se utiliza en labores de planeación, donde el procesamiento paralelo permitiría obtener simultáneamente resultados de múltiples casos.

1.2.2 Procesadores de arreglos

Un procesador de arreglos es una máquina de alta velocidad, capaz de procesamiento aritmético en paralelo, que generalmente necesita una computadora adicional para realizar el manejo de la base de datos. Aún cuando la velocidad de estas máquinas es inferior a la de una supercomputadora (Aproximadamente 10 MFLOPS), su costo es similar al de una estación de trabajo, por lo que resulta una buena opción en comparación con la primera. La desventaja que presentan es que se deben invertir esfuerzos en la codificación especial de los algoritmos de estabilidad transitoria. El desarrollo de compiladores adecuados tenderá a eliminar esta barrera gradualmente [36].

1.2.3 Equipos tipo estación de trabajo y técnicas de equivalentes

Entre las ventajas de los equipos tipo estación de trabajo están sus características gráficas, tamaño reducido y bajo costo. No son equipos que compitan en velocidad con una supercomputadora o un procesador de arreglos, pues no son capaces de procesamiento en paralelo, por lo que su uso es más recomendable en la planeación de la operación. Por otra parte, para mejorar su velocidad, su utilización debería combinarse con el desarrollo e implementación de nuevas técnicas de equivalentes dinámicos [46].

1.2.4 Métodos de la función de energía

Dentro de esta clasificación se engloban varias técnicas, basadas en la obtención de funciones de Lyapunov, utilizadas para evaluar los intercambios energéticos que ocurren en el SEP durante fenómenos dinámicos [34]. Se mencionan como ventajas de estos métodos la capacidad de obtener índices de estabilidad en forma rápida y directa, por lo que un resultado obtenido por éste método equivale a realizar varios estudios de estabilidad en el tiempo. Usualmente los índices se expresan como tiempos críticos de liberación de fallas. Entre las desventajas se tiene el hecho de que no se obtiene información adicional a los índices de estabilidad, además de que, en general sólo se analiza la primera oscilación.

1.2.5 Métodos Probabilísticos

Aún cuando la utilización de métodos probabilísticos se propuso inicialmente para la realización de estudios de estabilidad dentro del ámbito de la planeación de la expansión de sistemas eléctricos [49], se ha sugerido su empleo en la estimación de seguridad tanto en estado estable como dinámico [50]. El método propone la realización de estudios fuera de línea para encontrar las 'regiones de seguridad'. Su aplicación a problemas prácticos está actualmente en estudio.

1.2.6 Métodos de reconocimiento de patrones

La finalidad de estos métodos es el obtener funciones de clasificación relativamente simples [13], que sean capaces de distinguir si las condiciones actuales de operación pueden llevar al sistema a un estado estable o inestable [35]. Las razones que favorecen la utilización de estos métodos son, entre otras, las siguientes: 1) No es necesario emplear bases de datos extensas de la red en estudio, 2) Es posible utilizar modelos simples del sistema, 3) La metodología de análisis es sencilla 4) Se obtienen resultados simples (Estable o inestable). La principal desventaja es la necesidad de

realizar una gran cantidad de análisis fuera de línea, para generar los patrones de entrenamiento (base de conocimiento). La necesidad de un acceso rápido a todos los resultados obtenidos por el análisis previo, exige recursos de memoria. Esta es una desventaja que ha disminuido gradualmente al reducirse los costos de los equipos de cómputo.

1.2.7 Sistemas basados en conocimiento: Redes neuronales o sistemas expertos

Los sistemas basados en conocimiento se clasifican dentro de la rama de las técnicas computacionales conocida como inteligencia artificial. Al igual que para los métodos basados en reconocimiento de patrones, es necesario realizar una labor previa para obtener la base de conocimiento. En el caso de los sistemas expertos, la base de conocimiento se enuncia en forma de reglas lógicas [53-56]. Para las redes de neuronas artificiales, la base de conocimiento se forma internamente sintetizando la información generada por los casos de entrenamiento [1,2]. La mayor ventaja que puede obtenerse al utilizar estas opciones es la incorporación de cierta "inteligencia" al procesamiento de la información, lo que permite generalizar y obtener resultados plausibles para casos que no se presentaron en la etapa de entrenamiento. Como desventaja se menciona el hecho de que se utilizan técnicas heurísticas para la definición de algunos parámetros de la red; sin embargo las investigaciones en este campo son intensas [60,61].

En este trabajo se propone la utilización de un sistema basado en conocimiento, compuesto de varias redes de neuronas artificiales, cuyo ambiente de trabajo sea la sala de operación de un centro de control y que ofrezca a los operadores un índice de estabilidad de fácil interpretación. Las redes de neuronas artificiales deberán "aprender" la información de una serie de casos de estudio realizados previamente y, una vez entrenadas, para cada nueva condición de operación podrán obtener una estimación directa del nivel de seguridad transitoria en tiempo real.

1.3 Revisión Bibliográfica

Los problemas en que es posible aplicar redes de neuronas artificiales (RNA), son aquellos que implican procesos de clasificación, asociación, toma de decisiones y razonamiento [8]. No debe esperarse que una RNA resuelva eficientemente problemas que involucran cálculo aritmético.

Las investigaciones relacionadas con RNA, en el campo de los Sistemas Eléctricos de Potencia han abordado, entre otros, los siguientes temas: Pronóstico de carga [23,47,48], identificación de armónicas [24], control de generadores síncronos [25], identificación de fallas [3,26], análisis de estabilidad en estado estable [27], evaluación de seguridad [28-31] y estabilidad dinámica [32].

La primera referencia que propone la utilización de RNA's en el problema de estimación del nivel de seguridad dinámica de un sistema de potencia fué presentada por Pao y Sobajic en 1988 [28].

En este artículo, la aplicación de la metodología de RNAs se ilustra por medio del entrenamiento de una RNA para que estime el tiempo crítico de liberación de falla, de un sistema de prueba de seis nodos y cuatro generadores. Se plantean 30 casos de entrenamiento, variando la carga del sistema, con dos topologías base, en los que se aplica una falla trifásica, la cual se libera restaurando la topología previa a la falla, suponiendo la operación exitosa de un recierre automático.

Como variables de entrada se utilizaron variables dinámicas y de estado estable: Posiciones angulares iniciales de rotores relativas al centro angular de inercia, aceleración al inicio de la falla, y energía de aceleración de los generadores durante el período que dura la falla.

El método obtiene buenos resultados al probarse con patrones que tienen

topología diferente a las empleadas en los casos de entrenamiento, por lo que se concluye que el método permite una cierta generalización e independencia con respecto a la topología del sistema eléctrico. Pao y Sobajic utilizan una RNA de procesamiento progresivo con una capa interna. Se utilizan funciones de activación sigmoidales y el algoritmo de retropropagación de error.

En 1991 los mismos autores proponen un nuevo tipo de RNA [29], a la que denominan red de enlaces funcionales (Functional Link Net), por medio de la cual pueden efectuar procedimientos de aprendizaje supervisado y no supervisado. El primero lo utilizan para clasificación, mientras que el segundo se usa para agrupamiento de los patrones de entrada en conjuntos con características comunes. En [62] se ofrece una descripción detallada de este tipo de redes.

La idea fundamental de las redes de enlaces funcionales es el mejorar los patrones de entrada afectándolos por medio de transformaciones no lineales, antes de ser proporcionados a la red.

En esta referencia las variables de entrada utilizadas son: Potencia activa y reactiva generadas en el instante de falla, potencia mecánica, posición angular de rotores al aplicar la falla e inercia de las máquinas. La variable de salida es el tiempo crítico de liberación de falla.

Los valores estimados de la variable de salida resultan muy cercanos a los valores reales, en pruebas efectuadas con dos redes de enlaces funcionales.

Como ventaja adicional de este tipo de redes se reporta una mayor rapidez de aprendizaje, comparada con la obtenida por redes entrenadas con el algoritmo de retropropagación de error. Por otra parte, los sistemas de prueba utilizados son simples y no se reporta la posterior aplicación de este tipo de RNA en sistemas eléctricos de mayor tamaño.

En 1989 M. Aggoune y coautores [30], proponen la utilización de una RNA entrenada por medio de un algoritmo no iterativo, para estimar la estabilidad ante pequeñas perturbaciones de un sistema de prueba de tres generadores y nueve nodos. Por medio de estudios de estabilidad en la frecuencia se generan los patrones de entrenamiento y de prueba, utilizando los valores característicos del sistema para concluir estabilidad o inestabilidad.

Se analiza el empleo de diferentes grupos de variables de entrada, entre las que se tienen las siguientes: Potencia activa y reactiva generadas, valor de la ganancia de los sistemas de excitación, demanda en nodos específicos y estado (abierto-cerrado) de dos líneas de transmisión.

Los resultados muestran altos niveles de clasificación exitosa, con algunos errores de clasificación cerca de la frontera que separa zonas de estabilidad e inestabilidad. Se reconoce que parte del éxito de la clasificación se debe al tamaño del sistema de prueba y a la regularidad de los contornos de la frontera, por lo que una aplicación a sistemas de mayor tamaño requeriría la partición de las RNA's y del proceso de entrenamiento, o la especialización de las redes para reconocer situaciones específicas.

En 1994, V. Miranda y coautores [51], utilizan una combinación de algoritmos convencionales de optimización y RNA's para realizar un despacho de generación considerando análisis de seguridad transitoria en el sistema de prueba de CIGRE (7 generadores y 10 nodos). El algoritmo de optimización emplea una técnica similar al método de gradiente reducido, mientras que las RNA's se entrenan con el algoritmo de retropropagación de error con paso adaptivo.

Por medio del método de funciones de energía se obtienen valores del margen de estabilidad transitoria para una gran cantidad de condiciones de operación y se utiliza este margen como variable de salida para las RNA's. Las variables de entrada elegidas son potencias activas generadas, voltajes internos de generadores y constantes de inercia

de las máquinas. La utilización de estas variables de estado estable se basó en el hecho de que las pruebas utilizando variables dinámicas no mostraron mejoría en los resultados.

En este caso se utilizan las redes neuronales para estimar coeficientes de sensibilidad de la variable de salida (márgen de estabilidad), con respecto a las variables de entrada (potencias generadas). Los coeficientes de sensibilidad se emplean en el algoritmo de optimización, donde inciden directamente sobre las funciones de costo de generación.

Dentro de las condiciones de operación planteadas para generar los casos de entrenamiento se consideran varios niveles de demanda y diversas alternativas de despacho de generación, para una contingencia en particular sin variar la topología del sistema. Se admite que este método es de utilidad al considerar un número reducido de contingencias, y se comenta la obtención de buenos resultados en pruebas que consideran hasta cuatro contingencias diferentes.

También en 1994, Hobson y Allen [52] presentan resultados de la aplicación de la metodología de redes de neuronas artificiales en la estimación de estabilidad de primera oscilación. La conclusión alcanzada, en contraste con las referencias anteriores, es que las RNA's tienen dificultad para obtener respuestas exactas de manera consistente al considerar diferentes topologías en el sistema de potencia. Esto es, tienen problemas para generalizar los patrones aprendidos.

Se utilizan RNA's de procesamiento progresivo, entrenadas con el algoritmo de retropropagación de error, con una capa oculta y se proponen dos sistemas de prueba. Sistema 1: Cuatro generadores, 12 nodos, 16 líneas. Sistema 2: 20 generadores, 106 nodos y 156 líneas. El artículo solo presenta resultados considerando el Sistema 1, no fué posible aplicar la metodología de RNA's propuesta al Sistema 2.

Las variables de entrada utilizadas son las siguientes:

- (1) Potencia acelerante de cada generador al aplicar una falla. (P_{ai})
- (2) Valor al cuadrado de (1).
- (3) Posición angular de rotores, con referencia al centro de inercia, al liberar la falla. (δ_{di})
- (4) Susceptancia equivalente del sistema vista desde cada nodo de generación, al liberar la falla.
- (5) Ajuste de energía total del sistema. $\sum (P_{ai} \delta_{di})$.

La variable de salida es el tiempo crítico de liberación de falla.

Se comenta en este artículo la importancia de adecuar las variables de entrada por medio de un proceso de escalado y se sugiere que un primer paso útil es la división de los valores de las variables de entrada entre el valor promedio.

Los patrones de entrenamiento se generaron considerando cinco niveles de demanda y tres condiciones topológicas diferentes. Para cada uno de estos 15 puntos de operación se simularon fallas en los extremos de cada línea y se obtuvieron los tiempos críticos de liberación en cada caso. El proceso de entrenamiento de cada RNA se fijó en 20,000 iteraciones.

Considerando una RNA para cada una de las 15 condiciones de operación planteadas, se obtienen errores de entrenamiento que van desde un 3% hasta un 25%, no se menciona el número de patrones de entrenamiento que se presentan a cada red, pero se deben tener alrededor de 32 patrones (16 líneas y una falla en cada extremo).

Si se entrena una RNA para cada una de las tres condiciones topológicas, aumentan los porcentajes de error de entrenamiento a valores entre 31% y 35%. El aumento de los porcentajes de error es lógico considerando que aumenta el número de patrones de entrenamiento, que en este caso deben ser aproximadamente 160. El mayor error de entrenamiento (40%), se tiene al presentar todos los patrones (aprox. 480) a

una sola RNA.

No es posible conjeturar, en base a la información que presenta esta referencia, el motivo de los bajos porcentajes de clasificación exitosa; sin embargo, es posible que la organización de la información presentada a las RNAs no sea la más adecuada.

Las referencias anteriores resumen el estado del arte con respecto a la aplicación de la metodología de redes de neuronas artificiales al problema de estimación de estabilidad transitoria. Es de observarse que, aunque no existe una metodología claramente establecida, se puede concluir que existen ciertas guías generales:

Como variables de entrada se han utilizado tanto variables de estado estable como variables dinámicas, aunque al parecer no existe ventaja alguna al emplear estas últimas.

Las variables de salida que se han empleado son el tiempo crítico de liberación de falla [28, 29, 52], un índice de estabilidad basado en los eigenvalores del sistema [30], y el valor del margen de estabilidad transitoria [51]. Se requiere analizar comparativamente el desempeño de redes entrenadas con diferentes variables de salida, expresadas de diferente manera.

Una de las cinco referencias utiliza un algoritmo de aprendizaje no iterativo, sin embargo el número de patrones de entrenamiento en este caso es reducido. El resto emplea variantes del método de retro-propagación de error. La mejor variante es la que emplea un paso de tipo adaptivo.

Se requiere también analizar el efecto que tiene, en el aprendizaje de las RNAs, la manera de organizar los patrones de entrenamiento. Además, se debe estudiar si una adecuada organización permite obtener grupos de información relativamente independientes, con el propósito de aplicar la misma formulación a sistemas de potencia de mayor tamaño.

1.4 Estructura de la Tesis

En el primer capítulo se presentan inicialmente los motivos que dan origen a esta tesis, se continúa con una descripción general del problema central que se aborda, seguida por una breve revisión histórica de los métodos ideados para su solución; se define posteriormente la estructura general del trabajo y se finaliza presentando las aportaciones que se consideran más significativas.

En el capítulo II se presentan las bases conceptuales de las redes de neuronas artificiales y el reconocimiento de patrones. Se resume el desarrollo de las técnicas basadas en redes de neuronas artificiales, se presentan las características básicas de una neurona biológica y los modelos matemáticos que se utilizan actualmente para representar su comportamiento funcional, se comentan algunas de las arquitecturas más comunes y se describe el algoritmo de aprendizaje de retropropagación de error, el cual es uno de los más utilizados para entrenamiento. Se presentan las características relevantes de dos algoritmos de aprendizaje no supervisado, para finalizar con un resumen de la metodología de superficie de respuesta, que es un método basado en experimentos para analizar las relaciones funcionales entre las variables de entrada o de control de un proceso y la variable de salida.

En el capítulo III se describen los principales factores que afectan la estabilidad transitoria de un sistema de potencia, se presenta la red eléctrica de prueba que se utiliza para crear la base de datos, se definen los casos de interés, tanto los de entrenamiento como los de prueba y se presenta el concepto de espacio de generación, Se presenta un breve análisis del comportamiento dinámico de las variables para uno de los casos de estudio y se comentan algunas características del simulador utilizado para realizar los estudios de estabilidad.

El cuarto capítulo presenta la forma en que se aborda el problema utilizando la técnica de redes de neuronas artificiales y la metodología de superficie de respuesta. Se

comentan aspectos importantes del problema de representatividad y se describe en detalle el desarrollo de un sistema basado en redes de neuronas artificiales. Se consideran redes de una y dos capas internas con varias arquitecturas y se dan guías para la selección de la arquitectura más adecuada para este caso, de acuerdo a los valores de error durante las etapas de entrenamiento y prueba. Se aplica la metodología de superficie de respuesta, comparando los resultados obtenidos por ambos métodos. Se propone un sistema híbrido que combina las ventajas de ambas técnicas para reducir los errores de clasificación.

En el capítulo V se presentan diferentes alternativas de desarrollo de sistemas basados en redes de neuronas artificiales, aplicados a varios aspectos del problema de análisis de seguridad transitoria. La primera alternativa tiene que ver con la forma en que se maneja la información de la base de datos, agrupando ésta en conjuntos de patrones ya no separados por tipo de falla y voltaje, como se trató en el capítulo IV, sino por subespacio de generación. Esta forma de agrupar la información da lugar a cambios en el diseño de las redes de neuronas artificiales.

Se plantean también como alternativa diferentes variables de salida, y se analiza el desempeño de redes en cada caso, así como la utilidad de cada una de ellas desde el punto de vista del usuario final. La inclusión de controles suplementarios es uno de los aspectos más importantes para auxiliar en la toma de decisiones relativas a la seguridad. En una sección de este capítulo se presentan resultados de la inclusión de un control suplementario del tipo de disparo de generación en el sistema de prueba. Finalmente se presentan algunas ideas para la implementación práctica de los sistemas basados en redes de neuronas artificiales.

El último capítulo presenta las conclusiones de la tesis así como recomendaciones para futuros trabajos.

1.5 Aportaciones

Este trabajo presenta una alternativa viable para atacar el problema de estimación de estabilidad transitoria en línea, en sistemas de potencia longitudinales, empleando redes de neuronas artificiales. La metodología se ejemplifica por medio del diseño de un sistema basado en conocimiento, compuesto de 12 RNAs, que sirve para estimar la estabilidad transitoria de los generadores de dos importantes centrales pertenecientes al Area de Control Noreste del Sistema Interconectado Nacional.

Los resultados son de aplicación práctica inmediata a un problema presente en la operación de sistemas eléctricos. Los modelos de simulación utilizados para generar los patrones del comportamiento transitorio son los que se emplean en los centros de control Norte y Noreste para el análisis de la operación.

Para el entrenamiento de las RNAs se propone la utilización de una variante del algoritmo de retropropagación de error con paso adaptivo, que adiciona una señal de ruido controlada en cada paso iterativo. El algoritmo permite alcanzar valores de error mínimos en un número reducido de iteraciones (menor a 300).

Se investigan diferentes arquitecturas de RNAs. Se presentan resultados comparativos de redes con uno o dos niveles internos. Se analizan los casos de tener uno, dos o tres elementos de salida. Asimismo, se estudian las alternativas de utilizar diferentes variables de salida, expresadas de forma binaria o como variables continuas.

Como variables de entrada se proponen variables de estado estable, fáciles de obtener por medio de los sistemas de adquisición de datos disponibles, o utilizando algoritmos de estimación del estado de la red.

Se comparan detalladamente dos alternativas de organización de la información de entrada, para concluir acerca del efecto que producen sobre la capacidad de las

RNAs para 'aprender' (reducir los errores de clasificación).

Se propone la utilización de una interfaz gráfica para mostrar los límites de estabilidad a los operadores del sistema eléctrico, de manera sencilla. La herramienta podrá ser utilizada tanto en la operación en línea como para el entrenamiento del personal, ayudando en la toma de decisiones concernientes al despacho de energía de las plantas de interés.

El panorama dinámico se completa por medio de la inclusión de los efectos de controles discretos suplementarios, del tipo de disparo automático de generación, para evitar la pérdida de sincronismo. Los efectos de estos controles se reflejan en cambios en las zonas de estabilidad/inestabilidad, que se pueden apreciar en los diagramas de la interfaz gráfica.

Se presentan las etapas necesarias para la implementación del sistema basado en redes de neuronas artificiales, que se propone en la tesis, y que pueden servir de guía para evaluar el esfuerzo necesario para concretar su aplicación en casos particulares.

CAPITULO II

CONCEPTOS GENERALES SOBRE REDES DE NEURONAS ARTIFICIALES Y METODOLOGIA DE SUPERFICIE DE RESPUESTA

2.1 Introducción a Redes de Neuronas Artificiales

Una neurona es la unidad fundamental del sistema nervioso y constituye por lo tanto el elemento básico del cerebro. Un conjunto de neuronas interconectadas forma una red. Las complejas funciones del cerebro se realizan, de alguna manera, a través de redes de neuronas naturales.

El funcionamiento del cerebro es un problema complejo que ha dado lugar a diferentes hipótesis. Estas a su vez han requerido de la elaboración de modelos para demostrar su viabilidad. Existen diversas disciplinas interesadas en este problema, las que se pueden dividir en dos corrientes principales de pensamiento, de acuerdo con el tipo de modelos que emplean: Aquellas a las que interesa enfatizar los aspectos biológicos y las que dan más importancia a los aspectos tecnológicos [1].

A la psicología y la neurobiología, por ejemplo, interesa en mayor medida el estudio de las relaciones que se establecen entre las características biológicas y el comportamiento del individuo. Por otra parte, se encuentran las ciencias de la ingeniería, que se ven atraídas hacia este campo por el interés en obtener ideas que lleven al desarrollo de nuevas metodologías computacionales. De esta última área es de donde surgió inicialmente el interés por el estudio de las redes de neuronas artificiales.

La gran mayoría de las computadoras actuales procesa la información de manera algorítmica. Resuelven problemas realizando una serie de pasos lógicos y/o aritméticos. Estos procedimientos han sido previamente establecidos al analizar el problema que se trata. A pesar de que existen muchos problemas cuyo proceso de solución es bien conocido, existen otros para los que es difícil encontrar un algoritmo adecuado [2], por ejemplo, la conducción automática de automóviles, la lectura de caracteres escritos, la traducción de lenguaje oral, etc. La aplicación de redes de neuronas artificiales es una alternativa de solución a este tipo de problemas.

Por otra parte, no se considera que las redes de neuronas artificiales sustituirán el procesamiento convencional. En primer lugar, aún cuando existen comercialmente algunas computadoras que utilizan esta nueva tecnología [2], se pueden clasificar sólo como prototipos; además de que las áreas de aplicación se han limitado, hasta ahora, a cierto tipo de problemas. Predomina más bien la idea de que el procesamiento serie, (convencional), y el procesamiento paralelo de las redes neuronales se complementan y que en el futuro se podrá contar con procesadores híbridos que aprovechen las ventajas de uno y otro sistemas.

En este capítulo se ofrece inicialmente una breve descripción de la neurona biológica, de la que se han tomado sus características más significativas para elaborar modelos de neuronas artificiales. Se define la neurona artificial y se propone una clasificación de las redes de neuronas artificiales. Se revisan las formas en que las redes procesan la información y se plantea el algoritmo de aprendizaje de retropropagación del error. Posteriormente se describen las características básicas del método de superficie de respuesta, que se emplea para obtener modelos empíricos de procesos, utilizando técnicas como el diseño factorial de experimentos y el ajuste de funciones por mínimos cuadrados.

2.2 La Neurona Biológica

Los modelos de neuronas artificiales tienen como base a la neurona biológica. La Figura 2.1 muestra esquemáticamente una neurona típica [4].

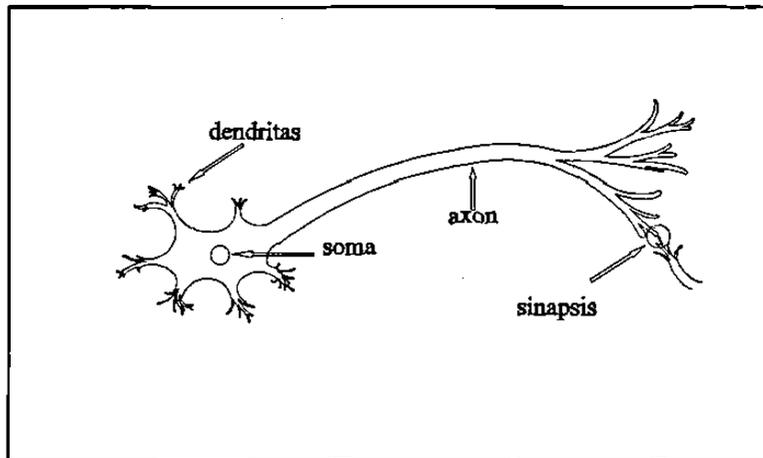


Fig. 2.1 Representación simplificada de una neurona.

Esta consta de tres regiones: El cuerpo principal o *soma*, el *axón* y las *dendritas*. Las dendritas son ramificaciones que reciben los impulsos provenientes de otras neuronas o de las terminales nerviosas de los órganos sensoriales. Las señales de salida de la neurona se envían a través del axón a otras neuronas o a los órganos motores. Los puntos de unión entre dendritas se denominan sinapsis. En la sinapsis se liberan transmisores químicos que afectan a la neurona receptora y propician o inhiben la creación de un impulso de respuesta.

La neurona responde a la suma de señales recibidas por sus dendritas en un intervalo dado de tiempo. Los impulsos recibidos pueden ser de excitación o inhibición, si contribuyen positiva o negativamente a que la neurona responda. Si la suma de señales de excitación es mayor que las señales de inhibición, por una cantidad denominada umbral, la neurona responde generando un impulso a través de su axón.

Las señales que recibe una neurona provienen por lo general de neuronas vecinas, o de ella misma. Se requiere un cierto número mínimo de impulsos para que una neurona se excite y hay más probabilidades de que lo haga si se reciben varios impulsos cercanos en el tiempo. El impulso que se genera no difiere significativamente en magnitud para diferentes respuestas; sin embargo, la neurona es capaz de actuar como un convertidor voltaje-frecuencia [4], cambiando la frecuencia con que emite impulsos de acuerdo con su nivel de excitación. Después de originar un impulso, la neurona permanece en un estado de inexcitabilidad por un corto período de tiempo. Para fines de simulación biológica este período se toma como 1 milisegundo.

En realidad existen diferentes tipos de neuronas, cada uno con características particulares, formando diversos tipos de redes, algunas incluso con retroalimentación. Se puede tener una idea general de la complejidad del proceso global que ocurre en el cerebro si se considera que se tienen alrededor de 10^{11} neuronas [21] y que la generación de impulsos es un proceso asíncrono, esto es, aleatorio en el espacio y en el tiempo.

2.3 Clasificación de Redes de Neuronas Artificiales

Las redes de neuronas artificiales (RNA), se pueden clasificar de acuerdo con tres de sus principales características [5]:

- 1) Tipo de neurona artificial.
- 2) Arquitectura de la red.
- 3) Regla de aprendizaje.

El primer aspecto se refiere al modelo matemático que se elige para la neurona artificial; a través del modelo se calcula la salida del elemento en función de las entradas. Por arquitectura de la red se entiende la forma en que se interconectan las neuronas, y por último, la regla de aprendizaje es el algoritmo por medio del cual se modifica la forma en que la neurona responde a entradas determinadas.

Todas las redes de neuronas artificiales exhiben, en mayor o menor grado, cierta capacidad para las actividades de:

- a) Auto-asociación.
- b) Hetero-asociación.
- c) Clasificación.
- d) Reconocimiento.
- e) Generalización.

Una vez que una red de neuronas ha pasado por el proceso de aprendizaje de un conjunto de patrones, es posible calcular una salida a partir de entradas dadas. El objetivo de esta actividad es recuperar información de la red; en términos computacionales esto equivale a decodificar la información almacenada.

La forma en que se recupera la información puede ser *auto-asociativa*; esto ocurre cuando se presenta como entrada un patrón similar a alguno de los almacenados y la red lo asocia con el patrón más parecido. Típicamente se elige como patrón de entrada una forma distorsionada de alguno de los patrones almacenados.

Se dice que la recuperación de información ocurre de manera *hetero-asociativa* cuando lo que se almacena son asociaciones entre patrones diferentes. También en este caso la red puede responder a patrones de entrada distorsionados.

El procesamiento se define como de *clasificación* cuando se almacena información de las clases a que pertenecen los patrones aprendidos. Cuando a la red se le presenta un patrón de entrada ya conocido, responde indicando la clase a la que pertenece.

Cuando el patrón de entrada no está dentro de los patrones de entrenamiento, el proceso se denomina *reconocimiento*. El patrón de entrada bien podría ser uno de los de entrenamiento con ruido adicional.

Una red *generaliza* bien cuando es capaz de interpolar y extrapolar, obteniendo salidas confiables cuando se le proporcionan patrones nuevos, no conocidos.

2.4 Tipos de Neuronas Artificiales

Una neurona artificial se define como un elemento de procesamiento que obedece a un comportamiento basado en las funciones de una neurona biológica.

Aún cuando desde 1890 se conocían los principios psicológicos que gobiernan el procesamiento de la información en el cerebro [6], en ese tiempo no se tenía el desarrollo tecnológico suficiente para plasmar esas ideas en un modelo matemático/computacional. Es hasta 1943 cuando McCulloch y Pitts [7] presentan el primer modelo formal de una neurona artificial, precursor de los actuales. Las características principales de este modelo (M-P), se resumen a continuación.

En el modelo M-P, mostrado esquemáticamente en la Figura 2.2, las entradas y salidas son señales binarias (0,1). La salida del elemento (y), en el instante $k+1$ se obtiene a partir de las entradas x_i , tomadas en el instante k , como:

$$y^{k+1} = \begin{cases} 1 & \text{si } \sum_{i=1}^n w_i x_i^k \geq u \\ 0 & \text{si } \sum_{i=1}^n w_i x_i^k < u \end{cases} \quad (2.1)$$

donde w_i son los pesos, que toman valor $+1$ ó -1 para señales excitatorias o inhibitorias respectivamente, y u es el valor umbral. La neurona responderá si la suma ponderada de las entradas excede el valor umbral.

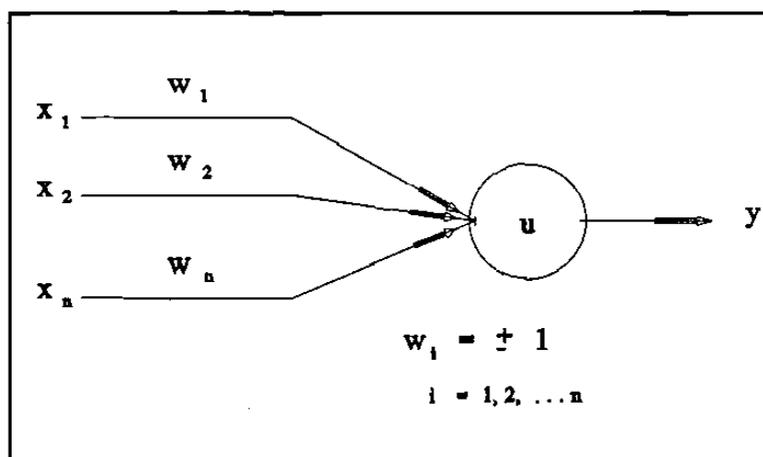


Fig. 2.2 Representación esquemática del modelo M-P.

Eligiendo adecuadamente los pesos (w_i) y el umbral u , el modelo M-P puede realizar las funciones lógicas AND, NOT y OR.

El modelo M-P opera en un marco de tiempo discreto, sólo permite estados binarios y supone sincronía en la generación de impulsos en una red. Estas simplificaciones se han superado actualmente y se cuenta con mayor flexibilidad en la especificación de las características de operación. A continuación se describen algunos de los principales modelos utilizados en la actualidad.

La Figura 2.3 muestra un diagrama del modelo general de neurona artificial. Consiste de un elemento o unidad de procesamiento, varias conexiones sinápticas de entrada y una salida. La señal de salida de la neurona se obtiene como:

$$y = f(w' x) \quad (2.2)$$

o bien

$$y = f\left(\sum_{i=1}^n w_i x_i\right) \quad (2.3)$$

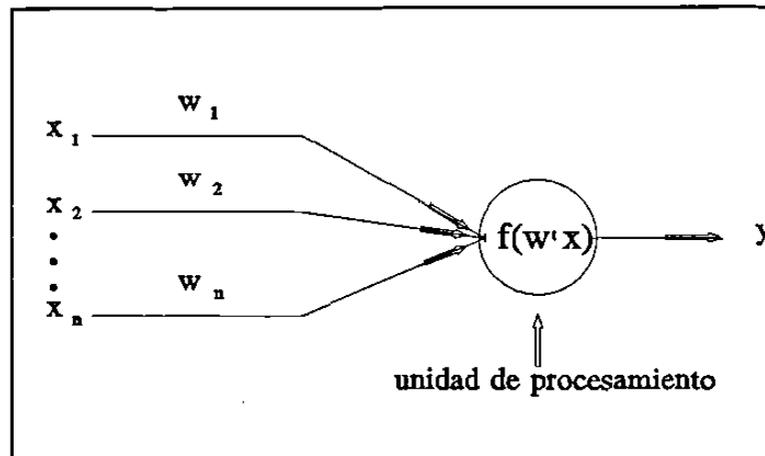


Fig. 2.3 Modelo general de una neurona artificial.

donde el vector de pesos (w) y el vector de señales de entrada (x), son:

$$w \doteq \begin{bmatrix} w_1 \\ w_2 \\ \cdot \\ \cdot \\ w_n \end{bmatrix} ; \quad (x) \doteq \begin{bmatrix} x_1 \\ x_2 \\ \cdot \\ \cdot \\ x_n \end{bmatrix} \quad (2.4)$$

La función $f(w'x)$ se conoce como función de activación. Su argumento es el producto escalar de los vectores w y x , que se conoce como salida lineal y .

Los diferentes tipos de neuronas artificiales se pueden clasificar de acuerdo con la función de actividad que utilizan, entre ellas:

- a) Escalón.
- b) Rampa.
- c) Sigmoidal.

Además, si el intervalo de valores de la función se extiende entre 0 y 1, o entre

-1 y 1, las funciones se denominan unipolares o bipolares [8] respectivamente.

La función de activación escalón unipolar se define por:

$$f(y_i) = \begin{cases} 1; & y_i > 0 \\ 0; & y_i \leq 0 \end{cases} \quad (2.5)$$

y la función de activación escalón bipolar como:

$$f(y_i) = \begin{cases} 1; & y_i > 0 \\ -1; & y_i \leq 0 \end{cases} \quad (2.6)$$

estas ecuaciones describen el modelo discreto de la neurona artificial.

Las funciones rampa unipolar y bipolar son:

$$f(y_i) = \begin{cases} 1; & y_i \geq u \\ \frac{y_i}{u}; & 0 < \frac{y_i}{u} < 1 \\ 0; & y_i \leq 0 \end{cases} \quad (2.7)$$

$$f(y_i) = \begin{cases} 1; & y_i \geq u \\ \frac{y_i}{u}; & -1 < \frac{y_i}{u} < 1 \\ -1; & y_i \leq -u \end{cases} \quad (2.8)$$

Las funciones sigmoideal unipolar y bipolar se pueden especificar como:

$$f(y_1) = \frac{1}{1 + e^{-y_1/\theta_0}} \quad (2.9)$$

$$f(y_1) = \frac{2}{1 + e^{-y_1/\theta_0}} - 1 \quad (2.10)$$

donde θ_0 representa la inclinación de la curva sigmoideal. Se observa que cuando θ_0 tiende a cero, el límite de la función sigmoideal tiende a ser la función escalón correspondiente. La Figura 2.4 muestra las funciones de activación mencionadas.

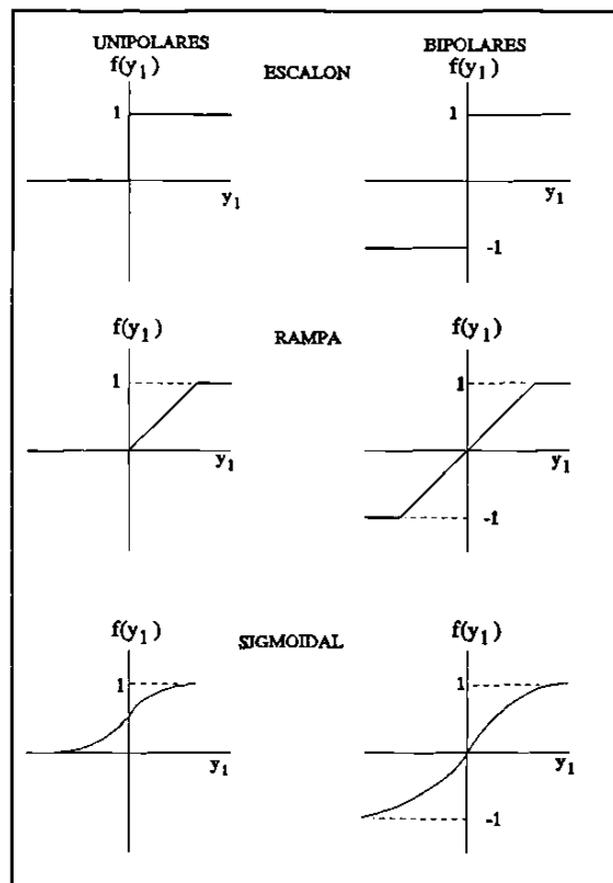


Fig. 2.4 Funciones de activación.

Las funciones rampa y sigmoideal describen un modelo continuo de neurona.

Utilizando las funciones de activación escalón y sigmoideal bipolares para el cálculo de la salida del modelo general de la Figura 2.3, se obtienen los modelos conocidos como perceptrón discreto y continuo respectivamente, propuestos por Rosenblatt [9] en 1958, y que se consideran como el primer modelo capaz de lograr aprendizaje.

2.5 Arquitectura de Redes

La trayectoria de las señales originadas por neuronas interconectadas sirve para clasificar la arquitectura de las redes neuronales en dos tipos:

- a) Redes de procesamiento progresivo.
- b) Redes con retroalimentación.

En la primera opción, la información sigue una trayectoria lineal desde la entrada hasta la salida. En el segundo tipo, existe retroalimentación de la información de salida.

Las neuronas en las redes de procesamiento progresivo se agrupan generalmente en capas. La Figura 2.5 muestra una red de una capa.

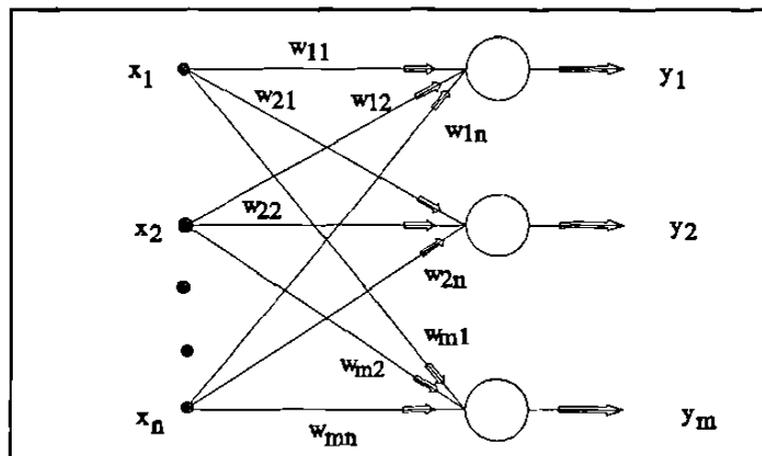


Fig. 2.5 Red neuronal de una capa.

Los vectores de entrada y salida son:

$$\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \\ \cdot \\ \cdot \\ x_n \end{bmatrix} ; \quad \mathbf{y} = \begin{bmatrix} y_1 \\ y_2 \\ \cdot \\ \cdot \\ y_m \end{bmatrix} \quad (2.11)$$

Los factores de ponderación w_{ij} conectan la i -ésima neurona con la j -ésima entrada. La salida lineal para la i -ésima neurona es:

$$y_{ii} = \sum_{j=1}^n w_{ij} x_j, \quad \text{para } i=1,2,\dots,m \quad (2.12)$$

La salida de la red se obtiene al aplicar la función de activación no lineal a cada una de las salidas lineales:

$$y_i = f(y_{ii}) = f(\mathbf{w}_i^t \mathbf{x}), \quad \text{para } i=1,2,\dots,m \quad (2.13)$$

donde el vector \mathbf{w}_i contiene los elementos de ponderación de los enlaces que convergen hacia la i -ésima neurona, que se define como:

$$\mathbf{w}_i = \begin{bmatrix} w_{i1} \\ w_{i2} \\ \cdot \\ \cdot \\ w_{in} \end{bmatrix} \quad (2.14)$$

En forma matricial, se describe el mapeo del espacio de vectores de entrada en el espacio de vectores de salida a través de la matriz de transformación no lineal \mathbf{T} , como sigue:

$$y = T [W x] \quad (2.15)$$

donde W es la matriz de ponderación, o matriz de conectividad:

$$W = \begin{bmatrix} w_{11} & w_{12} & \dots & w_{1n} \\ w_{21} & w_{22} & \dots & w_{2n} \\ \cdot & \cdot & \dots & \cdot \\ w_{m1} & w_{m2} & \dots & w_{mn} \end{bmatrix} \quad (2.16)$$

y

$$T = \text{Diag} [f(\cdot) \ f(\cdot) \ \dots \ f(\cdot)] \quad (2.17)$$

El vector de salida puede ser utilizado a su vez como entrada a otra capa de neuronas, donde se repite el procesamiento. De esta manera, se pueden crear redes de procesamiento progresivo de capas múltiples, como se ilustra esquemáticamente por la Figura 2.6. En la sección 2.7 se presenta un algoritmo de aprendizaje, por medio del cual se modifica la ponderación de los enlaces de la red.

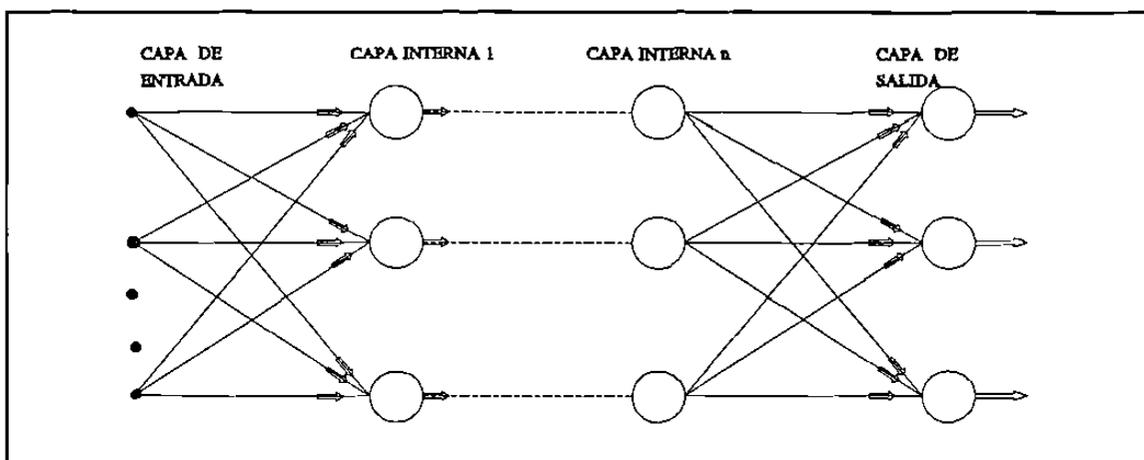


Fig. 2.6 Diagrama esquemático de una red de procesamiento progresivo de múltiples capas.

La Figura 2.7 muestra una red de una capa con retroalimentación. El comportamiento de este tipo de redes fue investigado inicialmente por Hopfield [10], introduciendo la variable tiempo dentro del procesamiento de información. La red se alimenta con un vector de entrada inicial, que se mueve a través de una secuencia de estados; cuando se llega a un estado estable (si existe), se obtiene la salida de la red.

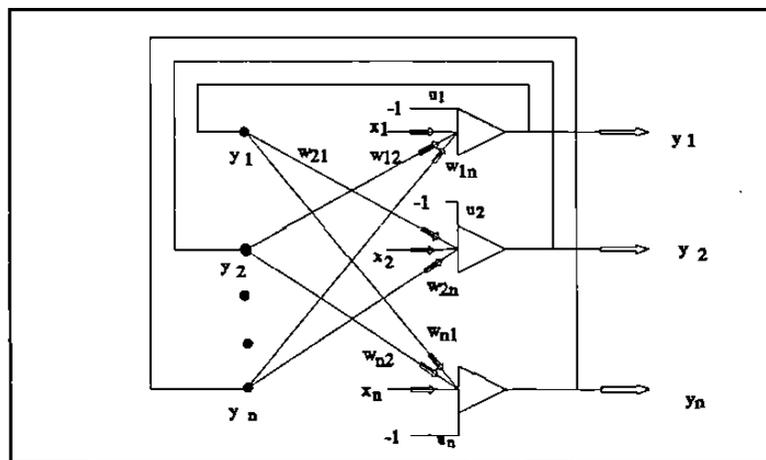


Fig. 2.7 Red de una capa con retroalimentación.

La red se compone de n neuronas, cada una con un valor de umbral u_i . La entrada lineal x_{ii} a la i -ésima neurona se compone de la suma ponderada de las salidas (y_j) de las otras neuronas, más su propia entrada x_i , menos el valor de umbral a vencer. Si w_{ij} representa el peso del enlace entre la salida de la j -ésima neurona y la entrada de la i -ésima, la entrada lineal de esta última se especifica como:

$$x_{ii} = \sum_{j=1, j \neq i}^n w_{ij} y_j + x_i - u_i \quad \text{para } i=1,2,\dots,n \quad (2.18)$$

En forma vectorial:

$$x_{ii} = w_i^t y + x_i - u_i \quad \text{para } i=1,2,\dots,n \quad (2.19)$$

donde w_i es el vector de pesos;

$$w_i = \begin{bmatrix} w_{i1} \\ w_{i2} \\ \cdot \\ \cdot \\ w_{in} \end{bmatrix} \quad (2.20)$$

e y es el vector de salida.

$$y = \begin{bmatrix} y_1 \\ y_2 \\ \cdot \\ \cdot \\ y_n \end{bmatrix} \quad (2.21)$$

La parte lineal de la red se describe matricialmente como:

$$x_i = W y + x - u \quad (2.22)$$

donde

$$x_i = \begin{bmatrix} x_{i1} \\ x_{i2} \\ \cdot \\ \cdot \\ x_{in} \end{bmatrix}, \quad x = \begin{bmatrix} x_1 \\ x_2 \\ \cdot \\ \cdot \\ x_n \end{bmatrix}, \quad u = \begin{bmatrix} u_1 \\ u_2 \\ \cdot \\ \cdot \\ u_n \end{bmatrix} \quad (2.23)$$

son los vectores de entrada lineal, de entrada externa y de umbrales respectivamente.

La matriz de conectividad W , se representa en forma expandida mediante la ecuación (2.24). Se observa que W es una matriz simétrica, con elementos cero en la

diagonal principal, lo que indica que la señal de salida de cualquier neurona se retroalimenta a todas, con excepción de ella misma.

$$W = \begin{bmatrix} 0 & w_{12} & w_{13} & \cdot & \cdot & w_{1n} \\ w_{21} & 0 & w_{23} & \cdot & \cdot & w_{2n} \\ w_{31} & w_{32} & 0 & \cdot & \cdot & w_{3n} \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ w_{n1} & w_{n2} & w_{n3} & \cdot & \cdot & 0 \end{bmatrix} \quad (2.24)$$

El vector de salida se actualiza recursivamente utilizando dos métodos: La actualización síncrona, en la que se calcula el vector de salida completo en cada paso, y la actualización asíncrona, en la que se calculan una a una las salidas de cada neurona, en un orden aleatorio. Esta última opción guarda mayor similitud con los procesos que ocurren en una red natural.

Considerando el tiempo como una variable discreta, la salida de la red se actualiza por medio de:

$$y_i^{k+1} = f(w_i^t y^k + x_i u_i), \quad \text{para } i=1,2,\dots,n \text{ y } k=0,1,2,\dots \quad (2.25)$$

donde la función de activación se considera del tipo escalón.

El caso más general, descrito en [10], que considera el tiempo como una variable continua y cuyo comportamiento se describe por medio de ecuaciones diferenciales, empleando funciones de activación continuas, se reduce al caso discreto cuando se utilizan funciones de activación escalón [8].

2.6 Reglas de Aprendizaje

Las reglas de aprendizaje son los algoritmos que sirven para modificar el valor de

los factores de ponderación, de tal manera que se obtenga la salida deseada.

El aprendizaje se puede efectuar de manera *supervisada*, cuando para cada entrada se conoce la respuesta deseada. Inicialmente la salida de la red puede estar muy alejada de la respuesta ideal, entonces se emplea el error entre ellas como medio para corregir el valor de las ponderaciones. Por lo tanto, se requiere de un grupo de patrones entrada-salida que serán el conjunto de patrones de entrenamiento de la red.

Cuando no se dispone de la información de la salida esperada, sino que se tiene sólo el conjunto de patrones de entrada, se aplica el modo de aprendizaje *no supervisado*, el que se utiliza generalmente para formar categorías dentro del conjunto de patrones, descubriendo características comunes o excluyentes. Mientras se realiza esta actividad, la red va ajustando las ponderaciones en un proceso que se conoce como de auto-organización.

Los procesos mencionados se efectúan generalmente por etapas, cambiando gradualmente las matrices de conectividad conforme se presentan secuencialmente los patrones de entrenamiento. Por otra parte, existe una regla de aprendizaje en la que se fijan los valores de las ponderaciones en un sólo paso, y que se utiliza para el diseño de redes empleadas como memorias asociativas. Estas redes poseen la estructura de las redes con retroalimentación.

2.7 Algoritmo de Retropropagación del Error

El algoritmo de propagación regresiva del error es una regla de aprendizaje supervisada, que se emplea en redes de procesamiento progresivo, y cuya forma básica se muestra a continuación, para un elemento de la red. La Figura 2.8 muestra la configuración esquemática de una neurona artificial conocida como elemento lineal adaptivo (Adaline [11]), en el que la salida lineal y_1 es procesada a través de una función no lineal.

La salida lineal para el k -ésimo patrón es la sumatoria de las entradas ponderadas mediante los factores (w_{ij}):

$$y_{l-k} = w_k^t x_k \quad (2.26)$$

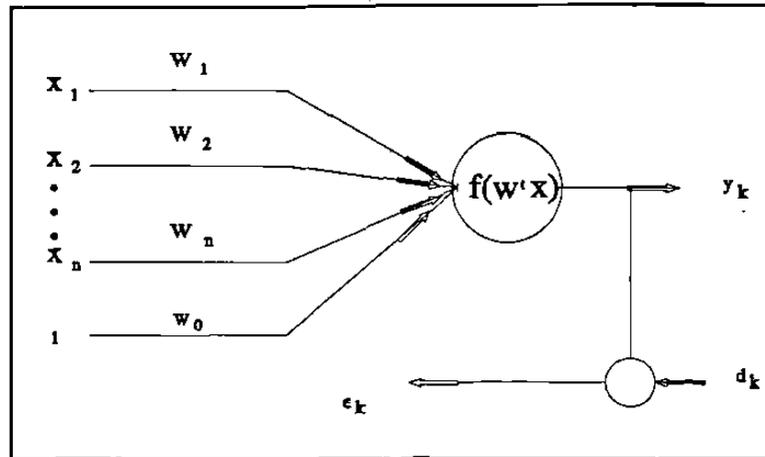


Fig. 2.8 Propagación regresiva del error en una neurona artificial.

En (2.26) se tiene que:

$$x_k = \begin{bmatrix} x_1 \\ x_2 \\ \cdot \\ \cdot \\ x_n \\ 1 \end{bmatrix}; \quad w_k = \begin{bmatrix} w_1 \\ w_2 \\ \cdot \\ \cdot \\ w_n \\ w_0 \end{bmatrix}$$

En este caso se emplea la función sigmoideal:

$$f_{sig}(y_{l-k}) = \frac{1}{1 + e^{-(y_{l-k}/\theta_0)}} \quad (2.27)$$

La función de la ecuación 2.27 es asintótica tendiendo a los valores 0 y 1 (sigmoidal unipolar).

La respuesta y_k de la neurona es el resultado de la función sigmoidal:

$$y_k = f_{sig}(y_{l-k}) \quad (2.28)$$

El error del k-ésimo patrón (ϵ_k), es la diferencia entre la salida deseada (d_k) y la obtenida por la red:

$$\epsilon_k = d_k - y_k = d_k - f_{sig}(y_{l-k}) \quad (2.29)$$

El objetivo del algoritmo de propagación regresiva es minimizar la media del error cuadrático promedio del conjunto de patrones de entrenamiento ($E[\epsilon_k^2]$), por medio de una selección apropiada de los valores de ponderación. Se utiliza el método de optimización de descenso rápido para minimizar el error, calculando el gradiente del error con respecto a las ponderaciones;

$$\Delta_k = \frac{\partial (\epsilon_k)^2}{\partial w_k} = -2\epsilon_k f'_{sig}(y_{l-k}) x_k \quad (2.30)$$

El algoritmo de actualización de los pesos es:

$$w_{k+1} = w_k + \mu(-\Delta_k) \quad (2.31)$$

$$w_{k+1} = w_k + 2\mu\epsilon_k f'_{sig}(y_{l-k}) x_k \quad (2.32)$$

En (2.32) el parámetro μ es conocido como factor de aprendizaje y regula el tamaño

del paso con que se avanza en el proceso de minimización. La derivada de la función sigmoïdal se obtiene como:

$$f'_{sig}(y_{l-k}) = (1 - y_k) y_k \quad (2.33)$$

En el caso de redes neuronales de varias capas, el error a minimizar es la suma cuadrática de los errores en la capa de salida:

$$\epsilon_t^2 = \sum_{i=1}^{ncs} \epsilon_i^2 \quad (2.34)$$

En la red neuronal mostrada en la Figura 2.9, el error a minimizar es la suma de ϵ_1 y ϵ_2 .

El error de cada neurona en la capa de salida se propaga regresivamente en la red, afectando a todos los pesos de los enlaces relacionados. Los errores en los elementos de una capa interna dada se definen en función de la derivada de error cuadrático de la siguiente capa y de los factores de ponderación de los enlaces que las unen. A su vez, estos errores sirven para obtener las derivadas de error cuadrático de este nivel. Una vez realizado esto, es posible actualizar las matrices de ponderación.

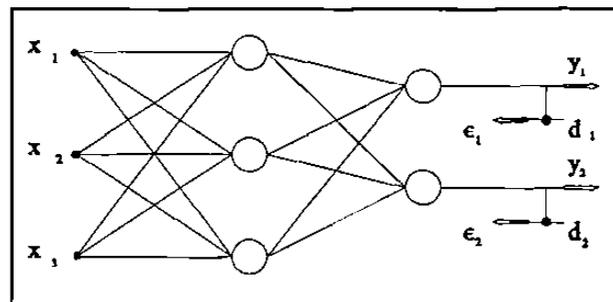


Fig. 2.9 Red Neuronal de 2 capas y 5 unidades de procesamiento.

El algoritmo de retro-propagación del error para redes de capas múltiples se muestra en el diagrama de flujo de la Figura 2.10.

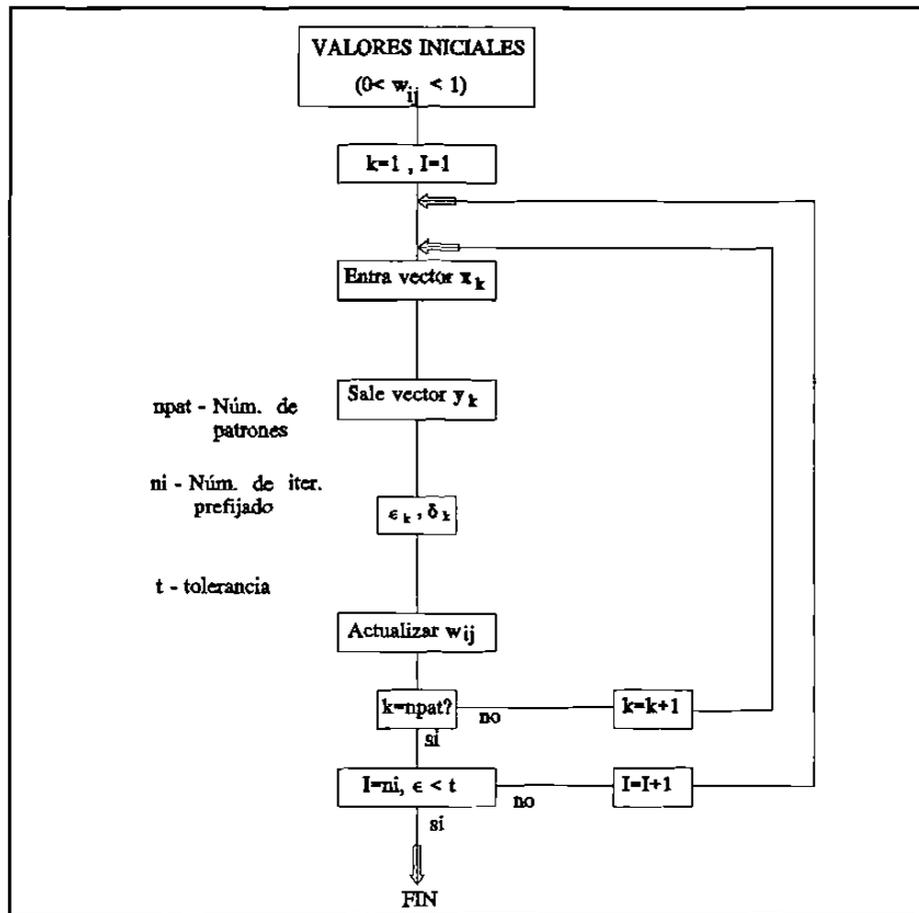


Fig. 2.10 Algoritmo de Retropropagación del error.

2.8 Algoritmos de aprendizaje no supervisado

Los algoritmos de aprendizaje supervisado (aprendizaje "con un maestro"), pueden establecer una clasificación de los patrones de entrada basados en el conocimiento de los patrones de salida. Un algoritmo de aprendizaje no supervisado debe ser capaz de descubrir las características importantes para distinguir entre patrones de entrada similares y diferentes, sin recurrir a información alguna acerca de los patrones de salida.

Para realizar este agrupamiento (clustering), se recurre a diversas medidas de

similitud. Una de las más comunes es la distancia euclídeana. La distancia entre los patrones x_i y x_j se expresa como sigue:

$$d_{ij} = \|x_i - x_j\|_2 = \sqrt{(x_i - x_j)' \cdot (x_i - x_j)} \quad (2.35)$$

Una vez calculadas por medio de (2.35) las distancias entre todos los pares de patrones, los grupos se forman definiendo una distancia umbral D_u , de tal manera que si la distancia d_{ij} es menor o igual al umbral D_u , los patrones x_i y x_j pertenecerán al mismo grupo, en caso contrario serán miembros de grupos diferentes.

También es común utilizar la expresión para calcular el coseno del ángulo entre dos vectores como medida de similitud. Considerando los patrones x_i y x_j , se tiene que el coseno del ángulo ϕ_{ij} se obtiene como:

$$\cos \phi_{ij} = \frac{x_i' x_j}{\|x_i\|_2 \cdot \|x_j\|_2} \quad (2.36)$$

Esta medida de similitud es más eficiente cuando se normaliza la longitud de los patrones a comparar, de tal manera que desde un origen de coordenadas determinado, x_i y x_j tengan magnitudes comparables, y en el caso óptimo, sean iguales.

Los dos algoritmos que se describen a continuación hacen uso de alguna de las medidas de similitud mencionadas para efectuar el agrupamiento y clasificación de los patrones.

2.8.1 Aprendizaje competitivo

En esta sección se presenta como ejemplo de aprendizaje competitivo la regla de aprendizaje conocida como "el ganador toma todo" [8]. Se aplica a redes de

procesamiento progresivo de una sola capa (Red de Kohonen), por lo que son válidas aquí las ecuaciones (2.11) a (2.17). En este caso, se debe definir de antemano el número de clases o categorías con que se desea trabajar. Esto equivale a definir el número de filas de la matriz de ponderación W . Cada vector fila de W representará un patrón "modelo" de una categoría, cuando la red haya sido entrenada. Los elementos de W son inicialmente números aleatorios pequeños, pero los vectores fila se deben normalizar antes de iniciar el proceso, con una magnitud unitaria. Si se elige la medida de similitud euclideana, la distancia mínima entre un patrón de entrada x y cada uno de los vectores fila de W coincide con el máximo valor del producto escalar entre W y x . La ecuación (2.37) muestra la obtención de la máxima salida lineal.

$$y_{ik} = \max_i \left[\sum_{j=1}^n w_{ij} x_j \right], \quad \text{para } i=1,2,\dots,m \quad (2.37)$$

El vector fila w_k de la matriz de ponderación es entonces el único que se actualiza, de acuerdo a:

$$\Delta w_{kj} = \alpha(x_j - w_{kj}), \quad \text{para } j=1,2,\dots,n \quad (2.38)$$

Esto significa que el nuevo vector w_k estará más cercano espacialmente al patrón de entrada que lo excitó. La dirección en que se mueve w_k es la contraria al gradiente, y la magnitud del paso (α), tiene un valor inicial entre 0.1 y 0.7, que se considera adecuado para la formación de los grupos principales. Conforme avanza el proceso de aprendizaje, el valor de α se debe hacer más pequeño para dar estabilidad al proceso. Se debe observar además que en este caso no es relevante la elección de la función de activación, la que debe ser del tipo continuo.

Existen algunas variantes de esta regla de aprendizaje. Por ejemplo, se puede ampliar el número de neuronas "ganadoras", y hacer participar a aquellas que están más cercanas a la que obtiene la salida máxima, o se puede hacer participar a todas, en forma proporcional a su respuesta. Por otra parte, si las categorías se conocen de

antemano, se puede idear una forma supervisada del método, en la que α sea positiva, para clasificación correcta y sea negativa en caso contrario.

2.8.2 Mapas auto-organizados [12]

Cuando se separan en grupos diferenciados un conjunto de patrones de entrada por medio de un algoritmo no supervisado, como el descrito en 2.8.1, implícitamente se están detectando y extrayendo las características que distinguen a cada grupo. Suponga que se elige inicialmente un número grande de patrones modelo. Cada patrón modelo forma un grupo o categoría, alrededor del cual se agrupará cierta cantidad de patrones de entrada. También existirán patrones modelo que no atraigan a ninguno de los patrones de entrada. Si se eliminan estos patrones no representativos, se puede llegar a un conjunto mínimo de patrones modelo, de tal manera que la clasificación no es óptima si el conjunto se reduce más. Este conjunto mínimo representará entonces a las características básicas necesarias para efectuar la discriminación. La dimensión del conjunto de características básicas es por lo general menor a la dimensión del espacio de los patrones de entrada.

Un mapa auto-organizado de características es una RNA que se entrena por medio del algoritmo no supervisado de Kohonen, que se describe enseguida.

La Figura 2.11 muestra un ejemplo de un arreglo bidimensional de neuronas artificiales. El patrón de entrada \mathbf{x} se aplica simultáneamente a todos los elementos en la red. En este caso se propone la actualización de los vectores de ponderación cercanos espacialmente (dentro de una vecindad V_m), al nodo con mejor respuesta, al que corresponde el vector de ponderación \mathbf{w}_m y que se obtiene al cumplir con (2.39).

$$\|\mathbf{x}-\mathbf{w}_m\| = \min_i \{\|\mathbf{x}-\mathbf{w}_i\|\} \quad (2.39)$$

La vecindad V_m , al inicio del proceso de aprendizaje puede abarcar un área considerable, pero se reduce gradualmente conforme avanza el algoritmo. Si la vecindad se reduce hasta abarcar solamente el nodo "ganador", el algoritmo se reduce al presentado en la sección 2.8.1.

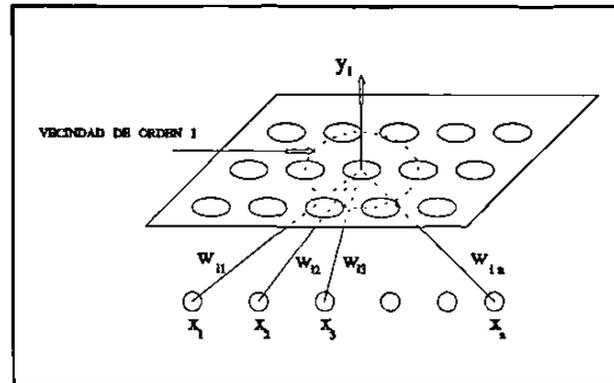


Fig. 2.11 Red de neuronas artificiales en arreglo bidimensional tipo mapa de características.

La actualización de la matriz de ponderación se lleva a cabo mediante:

$$\Delta w_i(t) = \alpha[x(t) - w(t)], \text{ para } i \in V_m(t) \quad (2.40)$$

Esto es, se actualizan todos los vectores fila w_i , de la matriz de ponderación, que se encuentran dentro de la vecindad V_m .

La longitud del paso de aprendizaje (α), es una función con valores en el intervalo (0,1), que depende de la vecindad V_m y del tiempo, por ejemplo, se ha empleado con buenos resultados la expresión:

$$\alpha(V_i, t) = \alpha(t) \exp\left[-\|r_i - r_m\|/\sigma^2(t)\right] \quad (2.41)$$

donde r_m y r_i son vectores que indican la posición de la neurona ganadora y de la neurona i , que se encuentra dentro de la vecindad, y $\alpha(t)$ y $\sigma(t)$ son funciones que dependen del tiempo de aprendizaje t .

La reducción de orden efectuada por la red, al mapear los patrones de entrada desde su espacio multidimensional al espacio bidimensional de características preserva la norma de distancia empleada, por lo que se obtienen agrupaciones de patrones explícitas y fáciles de observar.

2.9 Metodología de Superficie de Respuesta

La metodología de superficie de respuesta (MSR), está formada por varias técnicas que se emplean para el estudio empírico de las relaciones que se establecen entre una o más de las variables resultantes de un experimento (salidas) y las variables de control del mismo (entradas).

Los principales objetivos que se plantea el análisis de superficie de respuesta son entre otros, los siguientes:

- (a) Conocer el efecto de las diversas variables de control sobre la o las variables de salida dentro de una región de interés.
- (b) Determinar, si existen, los ajustes de las variables de control que permitirán obtener una salida deseada.
- (c) Determinar los valores de las variables de entrada con los que se obtendrá un máximo en cierta variable de salida, así como la forma de la superficie de respuesta cercana al máximo.

Las técnicas empleadas por el análisis de SR son básicamente el diseño factorial de experimentos y el ajuste de polinomios por mínimos cuadrados.

Las técnicas propuestas por la MSR se han aplicado exitosamente desde 1950 [41,42] en campos que van desde la ingeniería química, la agricultura y la ingeniería

mecánica, hasta la educación y la psicología. En México, dentro del campo de la ingeniería eléctrica se han utilizado para la verificación de diseños de fusibles [43] y en el análisis directo de estabilidad transitoria [44,45].

2.9.1 Diseño Factorial de Experimentos

Los modelos se pueden separar en dos grandes grupos: Modelos teóricos y modelos empíricos. La formulación de modelos teóricos es posible cuando el fenómeno bajo estudio es comprendido perfectamente y a partir de consideraciones teóricas se deriva una función que relaciona la respuesta con las variables. Cuando no se comprende suficientemente bien el fenómeno o éste es tan complejo que no permite la formulación de un modelo teórico, conviene utilizar un modelo empírico. Los resultados que se obtengan con él serán más adecuado cuando lo que se desea es aproximar la respuesta dentro de un rango limitado de las variables.

Muchos procesos son complejos y pueden ser investigados mejor a través de la experimentación. El objetivo de la experimentación es la obtención de datos que provean una mejor comprensión del proceso. Frecuentemente se tiene un gran número de variables involucradas y por lo tanto la experimentación resulta costosa. Las técnicas de diseño factorial de experimentos han mostrado ser útiles para minimizar los costos de los experimentos, mediante la reducción directa de el número propuesto de ellos, mejorando la calidad de la información útil.

El diseño factorial surge dentro del campo de la industria y tiene como objetivo mejorar la eficiencia de la experimentación y obtener la mayor cantidad posible de información al mínimo costo.

Si se eligen dos niveles de magnitud en las variables, el número de experimentos a efectuar está dado por 2^k . Un diseño factorial 2^k es aquel en el que intervienen k variables, y se tienen dos valores extremos para cada variable.

Considere un fenómeno a investigar en el que se tienen 3 variables independientes, (X, Y, Z), y como resultado se obtiene la salida S. La tabla 1 muestra la matriz de diseño propuesta para la realización de los $2^3=8$ experimentos.

Tabla 2.1

Matriz de Experimentos a Realizar

DATOS DEL DISEÑO FACTORIAL 2^3				
Prueba Num.	X	Y	Z	S
1	x1	y1	z1	s1
2	x2	y1	z1	s2
3	x1	y2	z1	s3
4	x2	y2	z1	s4
5	x1	y1	z2	s5
6	x2	y1	z2	s6
7	x1	y2	z2	s7
8	x2	y2	z2	s8

En este caso es posible mostrar gráficamente el diseño factorial como un cubo, Figura 2.12, donde las coordenadas de las aristas son los valores de las variables obtenidos en cada una de las ocho pruebas y a los cuales se les asigna el valor de la respuesta obtenida en esas condiciones.

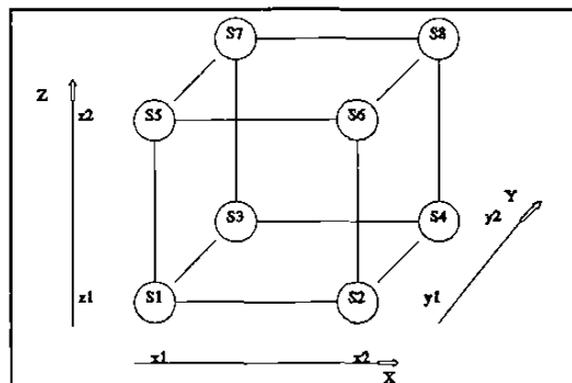


Fig. 2.12 Diagrama esquemático de un diseño 2^3 .

2.9.2 Ajuste de Funciones por mínimos cuadrados

Para simplificar los cálculos generalmente se proponen dos tipos básicos de funciones polinomiales de ajuste: Funciones lineales y funciones cuadráticas no lineales; sin embargo, teóricamente es posible proponer cualquier tipo de función no lineal de las entradas. La utilización de uno u otro tipo de funciones dependerá del grado de ajuste logrado con cada una de ellas.

Considerando las variables de entrada del inciso 2.9.1, es usual considerar como una primera alternativa una función lineal del tipo siguiente:

$$S = k_1 + k_2X + k_3Y + k_4Z + k_5XY + k_6XZ + k_7YZ + k_8XYZ \quad (2.42)$$

Los coeficientes de los términos con las variables de entrada solas se conocen como efectos principales, los coeficientes de los términos que combinan dos o más variables se conocen como efectos de interacción y pueden ser de segundo o de tercer orden, si combinan dos o tres variables. Es usual despreciar los efectos de orden superior a tres. La superficie de respuesta obtenida con este tipo de funciones son hiperplanos en el espacio definido por las variables de entrada. Al utilizar funciones cuadráticas, por ejemplo, se obtienen superficies curvas.

Cuando se tienen más de tres variables de entrada, se desprecian los efectos de orden superior a tres y se simplifica la función eliminando los efectos no significativos. Uno de los métodos gráficos para eliminar los efectos no significativos considera que éstos se mapean a una recta en coordenadas de probabilidad normal. Los efectos que quedan fuera de esta recta normal son los efectos significativos.

Otra de las técnicas para reducir el número de experimentos cuando se tiene más de cuatro variables, es la de utilizar una fracción del diseño factorial completo. Los

puntos seleccionados para realizar los experimentos se determinan eliminando las interacciones de alto orden.

2.9.3 Aplicación del Método

Considerando que se utilizarán solamente funciones lineales y cuadráticas, la metodología de superficie de respuesta se puede resumir en los siguientes pasos:

- 1) Definir el objetivo del análisis.
- 2) Seleccionar variables de entrada y salida, así como los rangos de variación de las variables de entrada.
- 3) Proponer un diseño de primer orden (función lineal), efectuar los experimentos, obtener los resultados y ajustar el modelo.
- 4) Si no se tiene un buen ajuste, proponer modificaciones a la función, ya sea en las variables de entrada o en las de salida, investigar el nuevo ajuste.
- 5) Si se logró un buen ajuste, investigar el grado de precisión de los resultados, si se desea aumentarla, proponer experimentos adicionales.
- 6) Si se satisfacen el ajuste y la precisión del modelo, terminar la investigación; si no es así pasar a 7).
- 7) Si no se logra un buen ajuste con el modelo de primer orden, proponer un modelo de segundo orden (función cuadrática), y ajustarlo.
- 8) Si el modelo de segundo orden no ajusta adecuadamente, proponer modificaciones al modelo o a la forma de las variables de entrada y/o salida.
- 9) Si se logra un buen ajuste, investigar el grado de precisión de los resultados; si no es suficiente, proponer y realizar experimentos adicionales.
- 10) Si se satisfacen el ajuste y precisión del modelo, terminar la investigación; si no es así, proponer un nuevo modelo.

CAPITULO III

EL PROBLEMA DE ESTABILIDAD TRANSITORIA

3.1 Introducción

Las redes eléctricas constituyen uno de los sistemas más complejos construidos por el Hombre. Debido a las ventajas de la utilización de la energía eléctrica, sobre otras formas de energía, su consumo es creciente y exige el desarrollo de sistemas eléctricos más grandes, más complejos, pero que a la vez sean más confiables y seguros.

El desarrollo histórico de los sistemas eléctricos, inclusive el de México, muestra etapas durante las cuales se tienen pequeñas redes operando en forma aislada, que siguen la tendencia a interconectarse para formar sistemas mayores [14]. Además de las ventajas económicas, se señala el apoyo durante emergencias y la compartición de reservas como las principales ventajas de la interconexión. El riesgo de la pérdida de estabilidad, es una de las desventajas que se aceptan al interconectar redes eléctricas.

En general [17], los estudios de estabilidad en sistemas de potencia se han agrupado en tres grandes grupos:

- a) Estabilidad de estado estable.
- b) Estabilidad dinámica.
- c) Estabilidad transitoria.

En el primer caso se analiza el comportamiento de la diferencia angular que se establece entre los fasores de voltaje interno de dos nodos de generación unidos por un

enlace de transmisión, ante cambios incrementales en el flujo de potencia en el enlace. La relación entre la potencia transmitida y la diferencia angular es una función no lineal que tiene un máximo en 90° . De esta manera se establece un límite de estabilidad en estado estable, considerando un margen práctico de alrededor de 30%, antes de que la diferencia angular alcance el valor máximo.

La estabilidad dinámica se encarga del análisis del comportamiento dinámico del sistema cuando ocurren pequeños cambios en variables como la carga o la frecuencia, por lo que también se le conoce como estabilidad ante pequeñas perturbaciones. El análisis por medio de programas de simulación digital requiere del modelado detallado de diversos elementos de la red y dispositivos de control, como cargas, generadores, sistemas de excitación, sistemas de gobernación, sistemas de estabilización, turbinas y calderas, etc. Debido a la magnitud de los cambios en las variables de control, es posible linealizar el modelo dinámico y realizar un análisis en el dominio de la frecuencia. Las conclusiones alcanzadas por estos estudios se pueden corroborar mediante simulaciones en el dominio del tiempo. El método es aplicable teóricamente a redes de cualquier tamaño y complejidad, la restricción práctica es fijada por la capacidad de los equipos de cómputo disponibles.

El terreno de la estabilidad transitoria abarca el comportamiento dinámico del sistema sujeto a grandes perturbaciones, como: El disparo de líneas debido a fallas, la pérdida de generadores y la conexión o desconexión de grandes montos de carga. La simulación en el tiempo es la herramienta aceptada generalmente para tratar con este problema, pues permite la reproducción más cercana al fenómeno real, sobre todo cuando se trata de una secuencia de eventos. El marco de tiempo que es posible analizar va desde uno hasta varios segundos. El requisito a considerar cuando se amplía el rango de tiempo es la inclusión de los modelos de los sistemas de control necesarios de acuerdo a las constantes de tiempo que los caracterizan.

En esta tesis los estudios de estabilidad transitoria se realizan por medio de

simulaciones en el tiempo. Se considera un tiempo de estudio de un segundo, por lo que no se considera necesario incluir los sistemas de gobernación, turbinas o calderas. Por simplicidad de modelado se omite también representar los sistemas de excitación. Las cargas se consideran variables en función del voltaje. Su comportamiento se caracteriza como un 70% de corriente constante y un 30% de impedancia constante. Se utilizan modelos simplificados de generadores de polos lisos para turbogeneradores y de polos salientes para unidades hidráulicas, (modelos I y II [19]).

Después de comentar los principales factores que influyen en la estabilidad transitoria, se presenta el sistema de potencia de prueba empleado, se destacan las características operativas de la red, que son comunes a varias plantas en el país, se definen los casos de estudio, se presenta el espacio de generación, que será una alternativa gráfica para mostrar el nivel de seguridad transitorio, se analiza el comportamiento dinámico de las variables de salida del estudio de estabilidad y se propone la construcción de los patrones de la RNA por medio de la generación automática de casos de estabilidad, lo que se realizó en este caso concreto por medio del simulador interactivo de sistemas de potencia (SISP) [59].

3.2 Factores que afectan la estabilidad transitoria

Se considera que entre los principales factores que afectan la estabilidad transitoria se tienen:

- a) Punto de operación.
- b) Tipo y localización de la falla.
- c) Tiempo de liberación.
- d) Forma de liberación de la falla.
- e) Controles discretos suplementarios.
- f) Robustez del sistema

Enseguida se presentan algunos aspectos relevantes de cada uno de estos puntos.

3.2.1 Punto de Operación

La condición de operación del sistema en su conjunto y de las plantas en forma individual afectan de manera determinante el comportamiento dinámico de los generadores. Durante el periodo de demanda máxima, la red de transmisión debe soportar flujos de potencia más elevados, que acrecientan el consumo de potencia reactiva. En estas condiciones se demanda mayor potencia activa y reactiva de los generadores. Las posiciones angulares relativas de los rotores aumentan, con respecto a las condiciones de carga media o baja, disminuyendo los márgenes de estabilidad de estado estable. El sistema de potencia está más propenso a la pérdida de estabilidad al ocurrir un disturbio. Cuando la demanda es menor y disminuyen los flujos de potencia por la red, disminuye el consumo de potencia reactiva en las líneas de transmisión, aliviando en alguna medida, la carga de potencia reactiva de los generadores. La reserva de potencia reactiva disponible permite soportar mejor el impacto inicial de una falla.

3.2.2 Tipo y localización de la falla

En un análisis de disturbios mayores, ocurridos en diferentes sistemas eléctricos [15], se encontró que las causas primarias de un disturbio pueden ser:

- a) De origen natural
- b) Por mal funcionamiento de equipo
- c) Por factores humanos

Cualquiera que sea el origen del disturbio, se puede modelar como una *falla*. Estas pueden clasificarse genéricamente [16] como fallas serie o fallas paralelo. En el primer tipo se involucran generalmente dos nodos, sin incluir la referencia, mientras que en el segundo tipo de falla se incluye una conexión a referencia o tierra. Desde el punto de vista de estabilidad, resultan más críticas las fallas paralelo, porque impiden en mayor medida la transmisión de potencia activa.

La gravedad de una falla será mayor en tanto provoque un desbalance de energía mayor entre la potencia mecánica y la potencia eléctrica. Cada generador percibe el disturbio inicial con diferente intensidad, de acuerdo a la distancia eléctrica con respecto a la falla. Entre más cercano eléctricamente se encuentre un generador a la falla, mayor será su respuesta eléctrica y por lo tanto mayor será la energía acelerante que actúe sobre el rotor. Las acciones de los sistemas de control tienden a reducir la diferencia entre las potencias mecánica y eléctrica. Se llegará a una nueva condición cuando este equilibrio se restablezca, si éste no se alcanza se produce la pérdida de sincronismo.

3.2.3 Tiempo de liberación

Durante el tiempo en que una falla es aplicada se reducen los voltajes de la red y se reduce la transmisión de potencia eléctrica de los generadores a las cargas. La potencia mecánica de los generadores no se reduce instantáneamente al nuevo valor de la potencia eléctrica y se produce una aceleración de la unidad. Mientras más tiempo dure aplicada una falla, más energía acelerante se le proporciona al generador. El tiempo crítico (t_c) de liberación de una falla es aquel para el cual el caso es críticamente estable. Si la falla se libera después de t_c la unidad pierde estabilidad. El tiempo crítico de liberación de una falla, que es en sí un índice de estabilidad, se puede obtener para cada falla realizando múltiples estudios de estabilidad o por los métodos de la función de energía [63].

3.2.4 Forma de liberación de la falla

La forma en que se libera una falla tiene que ver básicamente con el comportamiento de los sistemas de protección de la red. Si éstos actúan conforme se espera, la liberación de una falla no debe tardar más de unos cuantos ciclos y solo se debe remover de la red al elemento fallado. La desconexión, en el caso de líneas de transmisión, puede ser momentánea si se emplean esquemas de disparo y recierre, o permanente si no se dispone de ellos. La desconexión momentánea permite recuperar

la capacidad de transmisión inicial, con lo que se aumenta la posibilidad de regresar a estado estable, si la desconexión del elemento es permanente, no se dispone de la capacidad total de transmisión. El análisis de estabilidad debe considerar por lo tanto las características de los sistemas de protección existentes, incluyendo los modelos apropiados en las herramientas de simulación [58].

Si además se presentan fallas en la operación de los sistemas de protección (Relevadores, interruptores o medios de comunicación), la falla original puede persistir más allá del tiempo crítico y puede dar lugar al disparo innecesario de otros elementos en la red.

3.2.5 Controles discretos suplementarios

A diferencia de los sistemas de control de excitación o gobernación, cuya acción se ejerce de manera continua, los controles discretos actúan solamente en determinadas circunstancias, por lo general, después de detectarse la ocurrencia de un disturbio. Estos dispositivos tienden a mejorar la estabilidad del sistema, y se han ideado como una alternativa ante otras soluciones más costosas. En sistemas de potencia con estructura longitudinal resulta atractiva la utilización de controles discretos para soportar la operación en condiciones de emergencia, contando con cierto margen de seguridad [57], pues permite la utilización plena de la red de transmisión.

Enseguida se listan algunos tipos de controles suplementarios disponibles:

- a) Frenado dinámico
- b) Apertura y recierre tripolar
- c) Interruptores de alta velocidad
- d) Apertura y recierre monopolar
- e) Control discreto de sistemas de excitación
- f) Separación controlada
- g) Inserción de capacitores serie

- h) Disparo de generación
- i) Desconexión automática de carga
- j) Valvuleo rápido

Es importante considerar, por otro lado, que la inclusión de controles discretos suplementarios hace más compleja la operación del sistema [20] y se deben realizar extensos estudios de su comportamiento ante una gran cantidad de condiciones para identificar las posibles situaciones de riesgo que su uso involucra.

3.2.6 Requerimientos operativos en sistemas débiles

En sistemas eléctricos de estructura longitudinal, o sistemas débiles [18], con restricciones en la red de transmisión de potencia, los problemas de estabilidad se presentan entre plantas generadoras y centros de carga alejados geográfica y/o eléctricamente. El desarrollo transitorio de un evento, en este tipo de redes, ocurre por lo general en la primera oscilación, por lo que se deben implementar medidas de control de tipo preventivo. Entre ellas se cuenta, por ejemplo, con los controles discretos suplementarios. Es importante destacar que la decisión de la activación de los esquemas de control (mientras no se cuente con sistemas completamente automatizados), recae en el personal de operación, por lo que éste debe contar con medios "inteligentes" que le ayuden a elegir entre las opciones disponibles, aquella que mejor convenga, considerando el punto de operación actual, red de transmisión disponible, etc. Es conveniente que la ayuda que se brinde al operador se presente gráficamente y de la manera más sencilla posible.

3.3 Sistema de Prueba

El sistema de prueba consiste en la red de 230 y 400 KV asociada a la central Rio Escondido, ubicada en el estado de Coahuila, cerca de la frontera norte del país. La Figura 3.1 muestra un diagrama unifilar representativo de la zona, en el verano de 1992.

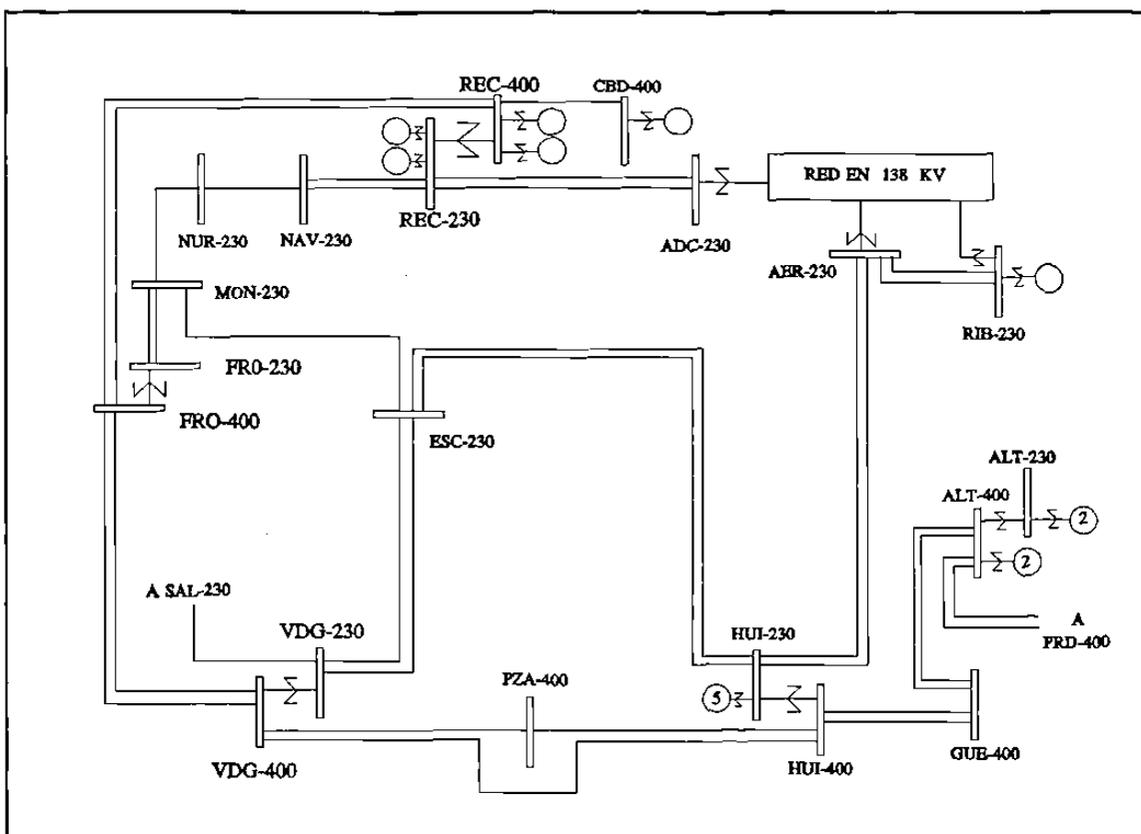


Fig. 3.1 Diagrama unifilar del área de interés.

Las plantas Rio Escondido (REC) y Carbón dos (CBD), generan energía eléctrica utilizando carbón como combustible. La primera de ellas cuenta con cuatro unidades de 300 MW de capacidad, mientras que la segunda tiene una unidad de 350 MW. En el futuro se planea añadir otra unidad en CBD así como una línea de transmisión en 400 kV saliendo desde esta planta. Las unidades REC-U1 y REC-U2, de la planta Rio Escondido, se conectan a la bahía de 230 kV y las unidades REC-U3 y REC-U4 se conectan a 400 kV. Las barras de 230 kV y 400 KV se unen por medio de un transformador de 300 MVA de capacidad.

La energía eléctrica se transporta a los puntos de consumo a través de dos líneas de 400 KV y cuatro de 230 KV. El número de líneas en la red de 230 KV se reduce al alejarse de la planta, con lo que se crean cuellos de botella para la transmisión de potencia, sobre todo cuando se presenta la pérdida de una de la líneas en 400 kV.

Operativamente, la red eléctrica de México se halla organizada en ocho subsistemas denominados áreas de control. La planta Rio Escondido pertenece al área de control noreste. La Figura 3.2 muestra las condiciones de generación y carga para la condición de demanda máxima de verano, para las áreas norte, noreste y para el sistema equivalente en el que se agrupan las áreas del sur del país.

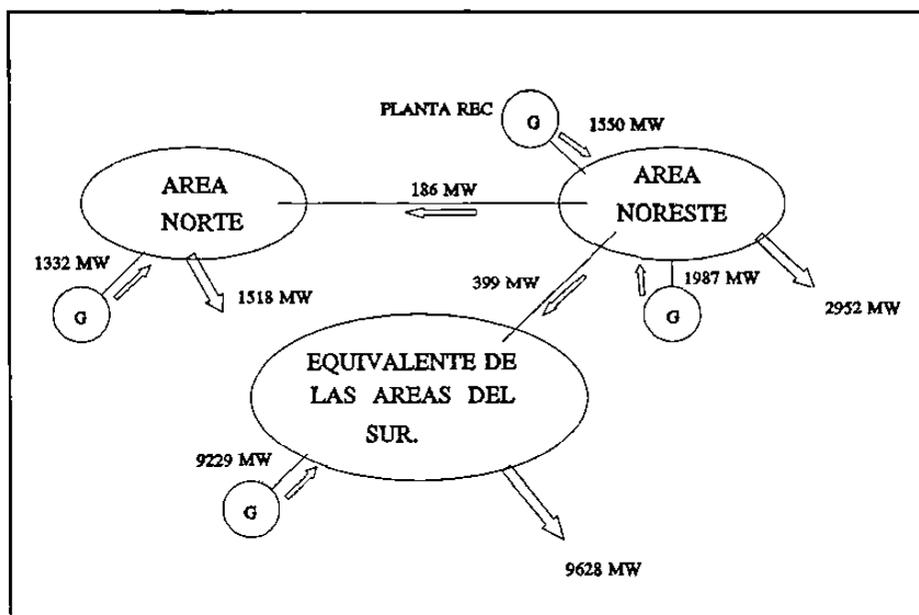


Fig. 3.2 Esquema global de distribución de carga por áreas.

No se consideró necesario el modelado detallado de las áreas del sur, debido a que la red de interés se encuentra eléctricamente alejada y la interacción electromecánica es reducida, además se tiene la ventaja de reducir el tiempo de cálculo tanto para los estudios de estado estable, como para los dinámicos.

En la condición de demanda máxima se modelan 227 nodos, 53 generadores, 243 líneas de transmisión, 87 transformadores y cinco elementos en derivación (reactores o capacitores). En la condición de demanda mínima solo se reduce el número de generadores necesario para satisfacer la carga en el sistema y se desconectan algunos elementos en derivación para propósitos de control de voltaje.

3.4 Casos de Estudio

Es posible plantear una gran cantidad de casos de estudio de estabilidad considerando las variables implicadas en el problema. Además del monto de generación de las unidades de Río Escondido, que será la variable de control, se tienen por ejemplo, las siguientes:

- a) La falla, que puede ser de varios tipos y ocurrir en sitios aleatorios de la red.
- b) El nivel instantáneo de la demanda, que depende del día y la hora que se elija para el estudio.
- c) La configuración del sistema, esto es las unidades generadoras, líneas de transmisión y transformadores conectados.
- d) Otras variables a considerar podrían ser los sistemas de excitación, la generación de otras unidades del sistema, etc.

Debido a la topología de la red asociada a la planta Río Escondido y considerando la experiencia obtenida en su operación se puede reducir el universo de casos posibles y analizar un pequeño conjunto, que incluya los casos críticos. Así, por ejemplo en lugar de considerar la gran variedad de fallas que se pueden presentar, se eligen dos tipos que representan casos extremos: La falla trifásica y la falla monofásica. Por otro lado estas fallas se aplican sólo en los nodos más cercanos eléctricamente a la planta (REC-230, REC-400 y FRO-400), para obtener los casos más críticos. A su vez se eligen tres configuraciones de la red: La primera es la que considera todas las líneas de transmisión en servicio, las dos restantes consideran una de las líneas de 400 kV fuera de operación, y que son las que imponen las mayores restricciones. En lo que respecta al número de generadores que pueden estar en servicio en la planta en un momento dado, se consideraron de interés tres casos: En el primero todas las unidades están sincronizadas, y en los otros dos se desconecta una unidad, ya sea en 230 o en 400 kV. En resumen, los casos de estudio considerarán las siguientes variables:

- 6 Tipos de fallas.
- 2 Montos de demanda.
- 3 Configuraciones de la red.
- 3 Configuraciones de generación.

En forma detallada:

Fallas:

- 1.- Falla trifásica en el nodo REC-230.
- 2.- Falla trifásica en el nodo REC-400.
- 3.- Falla trifásica en el nodo FRO-400.
- 4.- Falla monofásica en el nodo REC-230.
- 5.- Falla monofásica en el nodo REC-400.
- 6.- Falla monofásica en el nodo FRO-400.

Demandas:

- 1.- Demanda máxima de verano.
- 2.- Demanda mínima de verano.

En la Tabla 3.1 se muestra la carga total que se incluye en cada área en demanda máxima y mínima de verano.

TABLA 3.1
CARGA POR AREA [MW]

CONDICION	Area Norte	Area Noreste	Equiv. del Sur
Máxima	1518	2952	9628
Mínima	1245	2302	9628

Configuraciones de Red:

- 1.- Red completa.
- 2.- Una línea de transmisión REC-FRO en 400 kV, desconectada.
- 3.- Una línea de transmisión FRO-VDG en 400 kV, desconectada.

Configuraciones de Generación:

- 1.- Cuatro unidades en la planta Rio Escondido.
- 2.- Una unidad de REC-230 desconectada.
- 3.- Una unidad de REC-400 desconectada.

3.4.1 Casos de Entrenamiento

De la combinación de las condiciones anteriores se obtienen 108 casos de entrenamiento, correspondientes a las diferentes condiciones operativas planteadas. La Tabla 3.2 detalla los 18 casos generados para la falla 1. Las tablas descriptivas para las fallas 2 a 6 se encuentra en el apéndice A2. En base a las tablas, los casos 1111 y 2222 se traducen como sigue:

Caso 1111.- Falla trifásica en el nodo REC-230 en demanda máxima con las cuatro unidades de la planta sincronizadas, con la red de transmisión completa y la falla se libera disparando el banco de transformación de 400/230 kV.

Caso 2222.- Falla trifásica en el nodo REC-400 en demanda mínima, con la unidad REC-U3 desconectada, una línea de REC-400 a FRO-400 fuera de servicio y la falla se libera disparando la línea REC-FRO restante.

El tiempo que tarda en liberarse la falla en todos los casos es de 6 ciclos. Para las fallas en los nodos de 400 kV se supone falla en una de las líneas, liberada correctamente, sin considerar fallas en la operación de los relevadores que detectan la falla original, ni en los interruptores que disparan el equipo correspondiente.

En la columna de configuración de generación (U's), se indica con un cero la unidad que no se encuentra conectada, y bajo la columna de configuración de la red se establece que la red está completa (COMP) o se indica la línea que está fuera de servicio.

TABLA 3.2
CASOS DE FALLA TRIFASICA EN REC-230

CASO Núm.	FALLA	LUGAR	DEM.	U's	CONFIG.	DISP.
1111	3F	REC-230	MAX.	1234	COMP.	BANCO
1112	3F	REC-230	MAX.	1204	COMP.	BANCO
1113	3F	REC-230	MAX.	0234	COMP.	BANCO
1121	3F	REC-230	MAX.	1234	REC-FRO	BANCO
1122	3F	REC-230	MAX.	1204	REC-FRO	BANCO
1123	3F	REC-230	MAX.	0234	REC-FRO	BANCO
1131	3F	REC-230	MAX.	1234	FRO-VDG	BANCO
1132	3F	REC-230	MAX.	1204	FRO-VDG	BANCO
1133	3F	REC-230	MAX.	0234	FRO-VDG	BANCO
1211	3F	REC-230	MIN.	1234	COMP.	BANCO
1212	3F	REC-230	MIN.	1204	COMP.	BANCO
1213	3F	REC-230	MIN.	0234	COMP.	BANCO
1221	3F	REC-230	MIN.	1234	REC-FRO	BANCO
1222	3F	REC-230	MIN.	1204	REC-FRO	BANCO
1223	3F	REC-230	MIN.	0234	REC-FRO	BANCO
1231	3F	REC-230	MIN.	1234	FRO-VDG	BANCO
1232	3F	REC-230	MIN.	1204	FRO-VDG	BANCO
1233	3F	REC-230	MIN.	0234	FRO-VDG	BANCO

En cada caso se corren 25 simulaciones de estabilidad, con excepción de los casos 1121 y 1131, en que no se encuentra convergencia para la condición de máxima generación, por lo que se efectúan únicamente 24. La misma situación se presenta para todas las fallas, por lo que en total se obtienen 448 estudios de estabilidad por falla.

Para cada simulación de estabilidad se efectúa un estudio de flujos previo, para fijar las condiciones iniciales. En cada uno de los estudios de flujo se especifica una potencia activa de generación diferente en las unidades de la planta. En la sección 3.5 se describen las condiciones de generación que se asignan a las unidades.

3.4.2 Casos de Prueba

Para evaluar el desempeño del sistema de clasificación, se diseñaron una serie de casos de estabilidad, diferentes a los casos de entrenamiento. Las diferencias principales se encuentran en cuanto al monto de la carga nodal que se asigna al área de control Noreste. Se consideraron tres nuevas condiciones en la demanda: En la primera la carga es 10% mayor que la máxima, en la tercera la carga es 10% menor que la mínima, y en la segunda se tomó un promedio de las anteriores y se consideró como demanda media. En la Tabla 3.4 se muestra la carga total que se incluye en cada área.

TABLA 3.4
CARGA POR AREA [MW]

CONDICION	Area Norte	Area Noreste	Equiv. del Sur
Máxima	1518	3247	9628
Media	1518	2660	9628
Mínima	1245	2072	9628

La Tabla 3.5 describe los nueve casos que se simularon para la falla 1. En la columna de demanda (DEM.) se indica con MAXX la demanda 10% superior a la máxima y con MINN la demanda 10% inferior a la mínima. Las tablas descriptivas de los casos para las fallas 2 a 6 se encuentran en el apéndice A2.

En total se realizan 88 estudios de estabilidad por cada tipo de falla, pues existen dos condiciones iniciales en las que no se tiene convergencia debido a la combinación

de generación máxima con una línea de 400 kV fuera de operación.

Es importante destacar que los puntos de operación elegidos, esto es, la generación asignada a las unidades de la planta Rio Escondido, difiere también de la que se asigna a los casos de entrenamiento.

TABLA 3.5
CASOS DE FALLA TRIFASICA EN REC-230

CASO Núm.	FALLA	LUGAR	DEM.	U's	CONFIG.	DISP.
1111p	3F	REC-230	MAXX.	1234	COMP.	BANCO
1121p	3F	REC-230	MAXX.	1234	REC-FRO	BANCO
1131p	3F	REC-230	MAXX.	1234	FRO-VDG	BANCO
1211p	3F	REC-230	MED.	1234	COMP.	BANCO
1221p	3F	REC-230	MED.	1234	REC-FRO	BANCO
1231p	3F	REC-230	MED.	1234	FRO-VDG	BANCO
1311p	3F	REC-230	MINN.	1234	COMP.	BANCO
1321p	3F	REC-230	MINN.	1234	REC-FRO	BANCO
1331p	3F	REC-230	MINN.	1234	FRO-VDG	BANCO

3.5 El espacio de generación

Para mostrar gráficamente los resultados de los casos, se define un espacio de generación como un esquema bidimensional formado de 25 pares (X,Y); donde X es la generación de las unidades conectadas a 230 KV en la planta Rio Escondido y Y es la generación de las unidades conectadas en 400 KV. Considerando que la generación puede cambiar en pasos discretos de 50 MW, y que 100 MW es la mínima generación permitida por unidad, se obtiene el espacio de generación que se muestra en la Figura

3.2. Los círculos señalan los puntos operativos en los que se realizan los casos de entrenamiento. Los cuadrados negros indican la generación para los casos de prueba.

Analizando seis tipos de falla, para dos niveles de demanda, tres diferentes configuraciones de la red y tres configuraciones de generación, se originan 2700 estudios de estabilidad, que conforman los casos de entrenamiento.

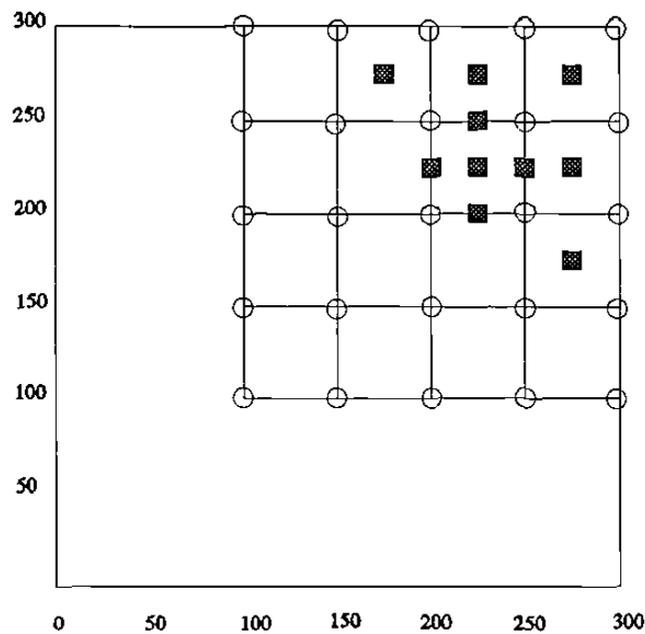


Fig. 3.3 Espacio de generación.

Con respecto a los casos de prueba, se generan 540 estudios de estabilidad, ya que sólo se toman 10 puntos operativos y una sola configuración de generación para los seis tipos de falla, tres demandas y tres configuraciones de red.

Como resultado principal de los análisis de estabilidad se obtiene la variación angular de los rotores de los generadores del sistema con respecto a una máquina de referencia. Por medio de estos resultados se pueden separar los casos estables de los inestables y mostrar gráficamente dentro del espacio de generación. La Figura 3.4 muestra la variación angular de la unidad REC-U2 cuando en el sistema ocurre la falla

descrita por el caso 1111.

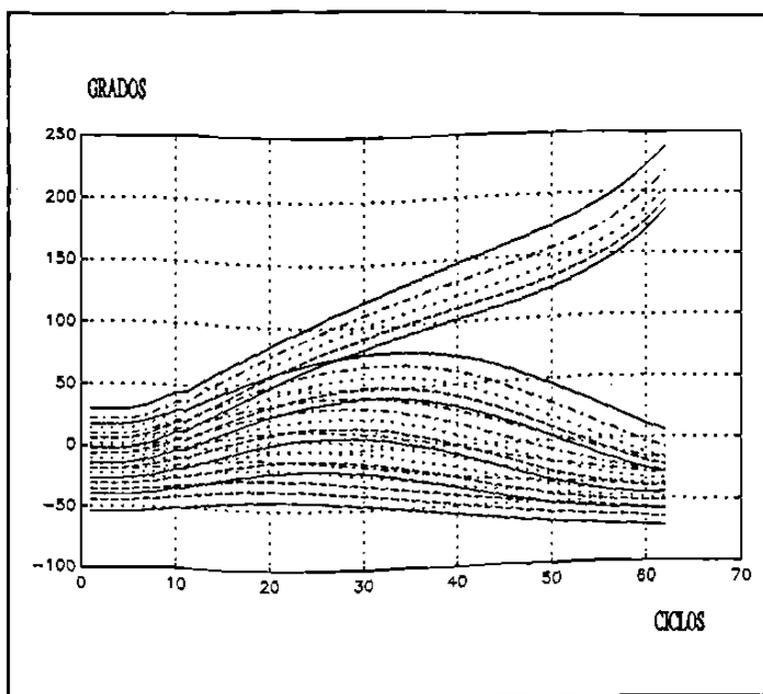


Fig. 3.4 Diferencia angular de REC-U2. Caso 1111.

En cinco de los 25 casos de estabilidad simulados, se encontró pérdida de sincronismo de las unidades conectadas a la barra de 230 kV. El comportamiento dinámico de la unidad REC-U2 se denota en estos casos por un crecimiento rápido y sin retorno de la posición angular, como se observa en la Fig. 3.4.

Para una condición de operación, fijada por la demanda del sistema y la configuración de la red, se tendrán puntos del espacio de generación que no deben ser ocupados si no se quiere correr el riesgo de inestabilidad ante diferentes contingencias. Una contingencia define un patrón de estabilidad dentro del espacio de generación. Los puntos negros en la Figura 3.5 corresponden a los casos inestables de la Figura 3.4. Los círculos blancos indican puntos de operación estables cuando ocurre la falla analizada. Se podría lograr mayor definición de los límites de estabilidad realizando simulaciones en la zona intermedia que separa casos estables e inestables.

En la Figura 3.6 se muestra el patrón de estabilidad obtenido para las unidades conectadas en 400 kV. Al superponer los patrones de estabilidad de las Figuras 3.5 y 3.6 se obtendrá la zona de seguridad total de la planta para esta contingencia. Los patrones de estabilidad pueden ser una ayuda gráfica para comprender la gravedad de una o más contingencias, considerando el área factible en la que se puede operar.

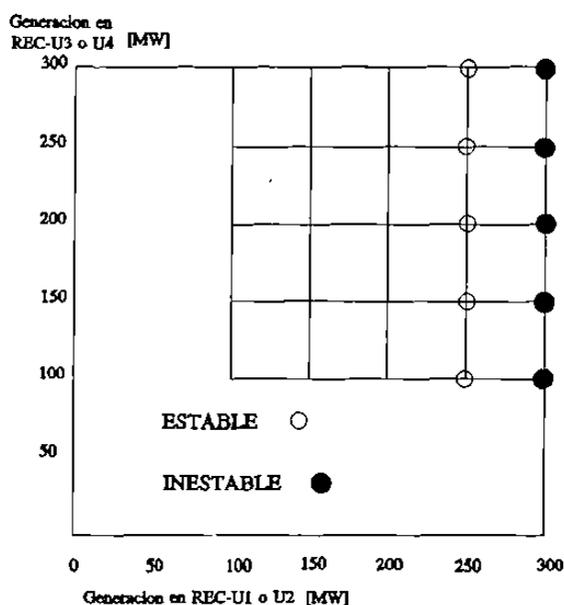


Fig. 3.5 Límites de estabilidad para las unidades conectadas en 230 KV. Caso 1111.

Separando los patrones de estabilidad de las unidades conectadas en 230 kV y de las unidades conectadas en 400 kV, si se considera que en general serán diferentes, se podría esperar encontrarse con 216 diferentes patrones de estabilidad. Sin embargo, el número de patrones de estabilidad observados fue alrededor de 40. Esto se debe a que varios casos dan lugar al mismo patrón de estabilidad, por ejemplo, en alrededor de 30 casos no se presenta inestabilidad para ninguna condición de carga tanto para las unidades conectadas a 230 kV, como para las conectadas a 400 kV, por lo que todos estos casos se agrupan en un solo patrón de estabilidad sin puntos negros, similares al de la Fig. 3.6.

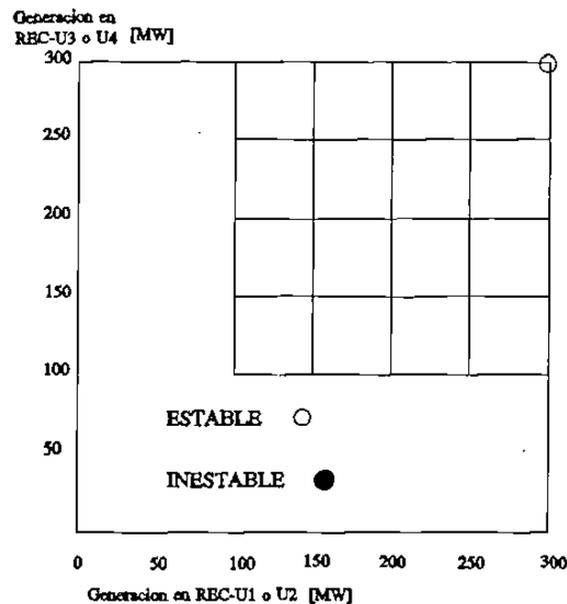


Fig. 3.6 Límites de estabilidad para las unidades conectadas en 400 KV, para la contingencia 1111.

Alrededor de 13 casos dan lugar a un patrón con un solo punto de inestabilidad, para la máxima generación. Por supuesto existen casos especiales que originan patrones de estabilidad únicos. Se detectaron 14 casos de este último tipo.

Otros casos especiales son aquellos que generan un patrón de estabilidad en donde para todos los puntos de operación se obtiene inestabilidad para la falla planteada. Se encontraron al menos 5 casos en que el comportamiento dinámico de la planta completa se describe por este tipo de patrón de inestabilidad.

Es fácil almacenar la relación casos-patrones de inestabilidad, en una tabla de datos, sin embargo ésta sería una relación fija, que no proporcionaría información cuando las variables del sistema no fueran aquellas con las que se realizaron los estudios de estabilidad. Es por esta razón que surge la necesidad de una herramienta que sea capaz de abstraer las reglas que rigen el comportamiento dinámico del sistema eléctrico en estudio en base a los ejemplos que plantea cada caso, y que además tenga la capacidad de generalizar para ofrecer respuestas para aquellas condiciones de carga o

generación que no se simulan.

3.6 Análisis de las variables de salida

Las variables que se eligen para observar el comportamiento dinámico del sistema son: Las potencias activa y reactiva generadas en las unidades de la planta Rio Escondido, la posición angular relativa de las unidades de la planta con respecto a un generador equivalente de las plantas del sur del país, localizado en la barra Poza Rica Dos (PRD), y la aceleración angular de las unidades de la planta. El comportamiento de estas variables se ejemplifica para el caso 1111 en las figuras que se muestran a continuación.

La Figura 3.7 muestra la posición angular de la unidad REC-U4. Se observa que no pierde estabilidad ante esta falla, en contraste con las unidades conectadas a la barra de 230 kV, cuyo comportamiento se observó en la Figura 3.4.

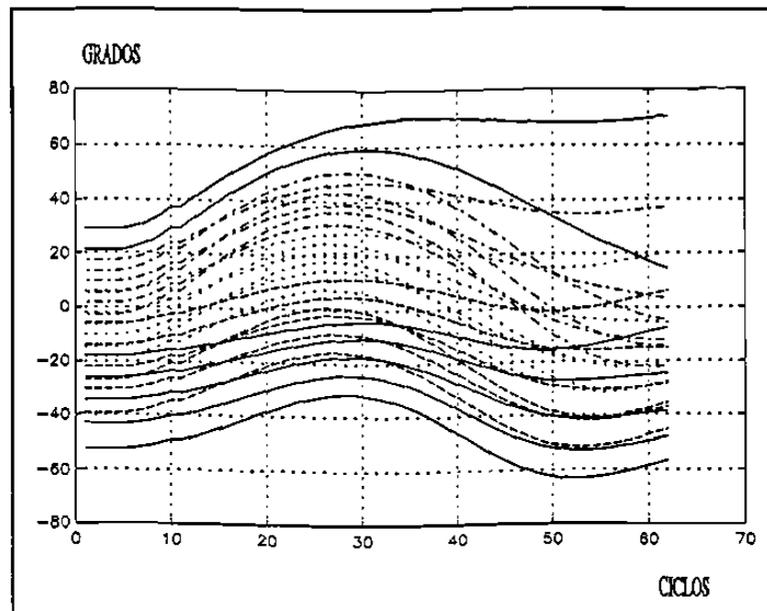


Fig. 3.7 Posición angular de REC-U4. Caso 1111.

En las Figuras 3.8 y 3.9 se grafica la potencia activa generada por las unidades REC-U2 y REC-U4, respectivamente. Durante la aplicación de la falla la potencia de las unidades en 230 kV se reduce a cero.

Las unidades conectadas a 400 kV reducen la potencia generada durante la falla a valores menores que los iniciales, como se observa en la Figura 3.9, sin llegar a cero. Posteriormente a la liberación de la falla se producen oscilaciones alrededor del punto de operación inicial, que caracterizan a los casos estables.

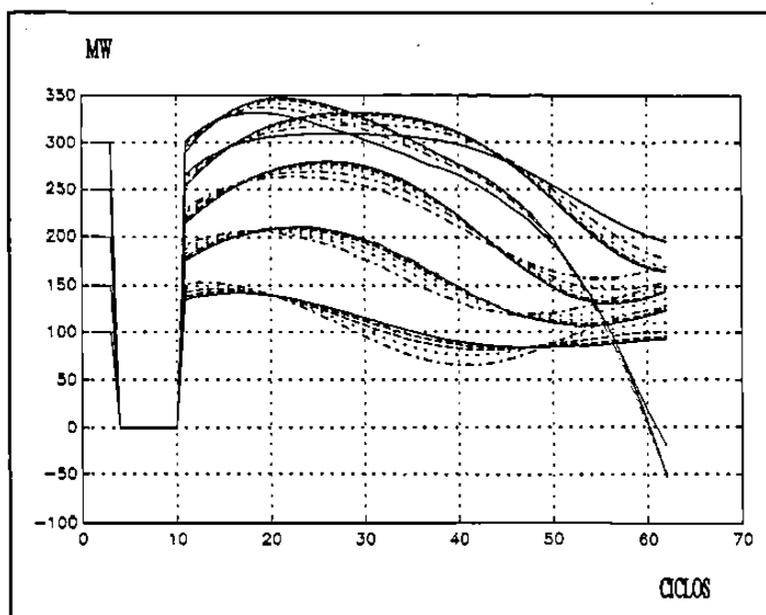


Fig. 3.8 Potencia activa de REC-U2. Caso 1111.

En la Fig. 3.8 se puede comparar el comportamiento que caracteriza a los casos estables e inestables, desde el punto de vista de potencia activa. En todos los casos, después de la falla, existe una tendencia a aumentar la potencia eléctrica generada, para aliviar el exceso de energía acumulada por el generador durante la falla. Los casos estables ilustran el hecho de que esta energía logra transmitirse por la red y repartirse a otros generadores del sistema. En los casos inestables la tendencia inicial a aumentar la generación de potencia se ve frenada, quizá debido a las restricciones impuestas por la red de transmisión, y se observa un rápido descenso por debajo del valor inicial, hasta llegar a cero y empezar a incursionar en valores negativos.

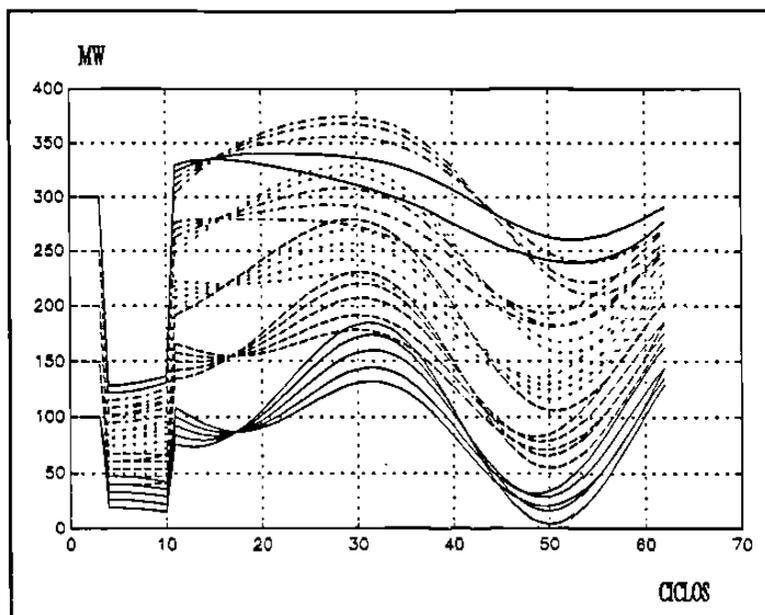


Fig. 3.9 Potencia activa de REC-U4. Caso 1111.

En las Figuras 3.10 y 3.11 se muestra el comportamiento de la potencia reactiva generada por REC-U2 y REC-U4 respectivamente, para la falla descrita por el caso 1111.

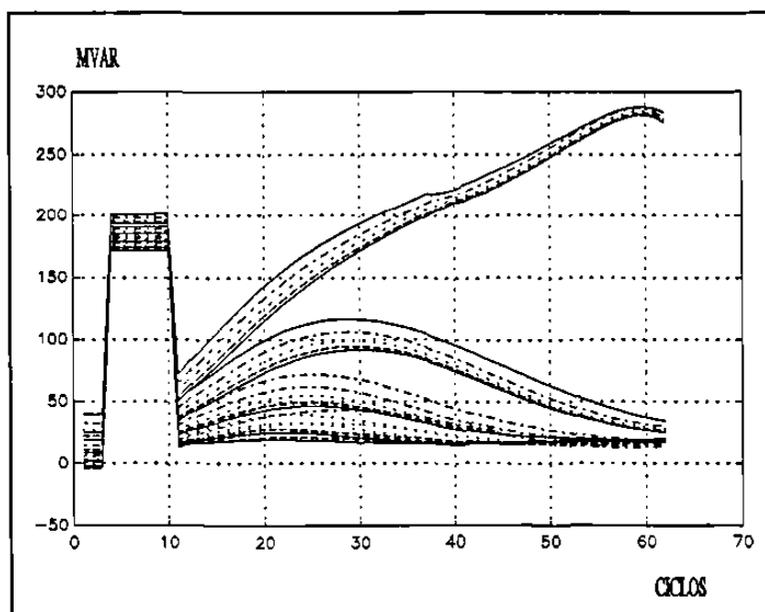


Fig. 3.10 Potencia reactiva de REC-U2. Caso 1111.

Los casos inestables de la Fig. 3.10 se caracterizan por un aumento sostenido de la demanda de reactivos por la red, hasta alcanzar un cierto valor límite. En los casos estables de la misma figura, se observa una tendencia a restablecer los valores de potencia reactiva generados antes de la falla.

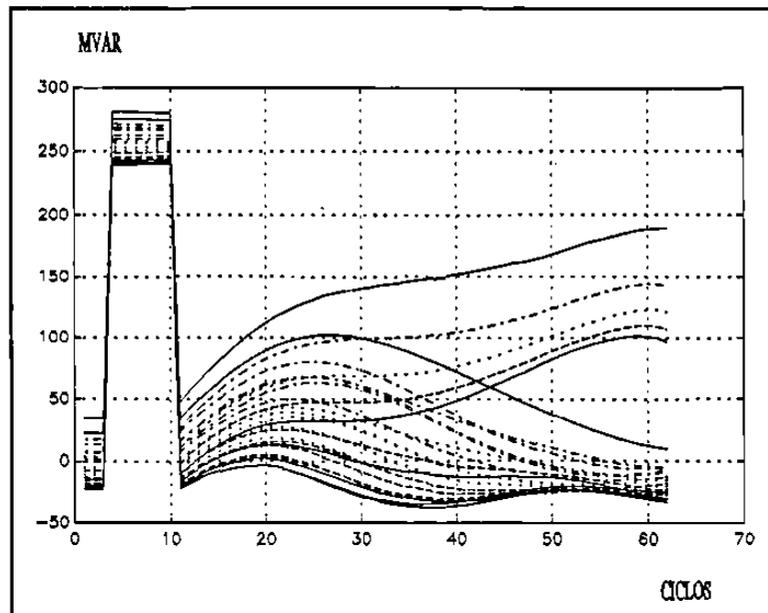


Fig. 3.11 Potencia reactiva de REC-U4. Caso 1111.

El comportamiento de la aceleración angular de las unidades REC-U2 y REC-U4 se ilustra en las gráficas de las Figuras 3.12 y 3.13. Después de los altos niveles de aceleración que se producen debido a la falla, se encuentran valores negativos para los casos estables.

En los casos inestables de la Figura 3.12, se observa una tendencia creciente a aumentar los valores de aceleración después de un cierto lapso de tiempo.

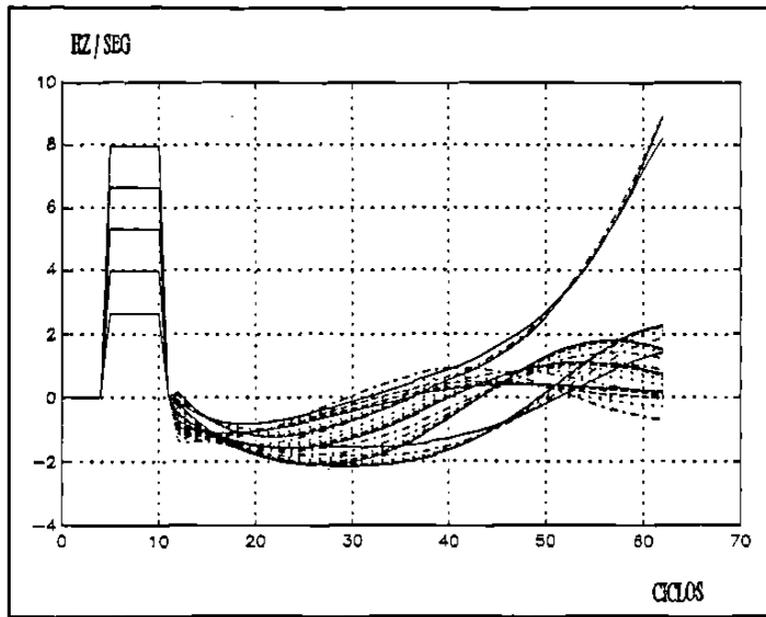


Fig. 3.12 Aceleración de REC-U2. Caso 1111.

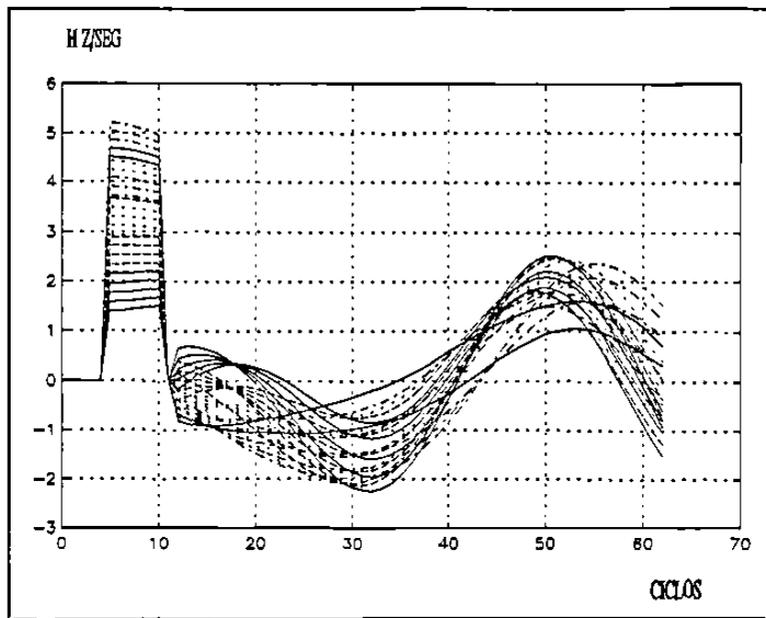


Fig. 3.13 Aceleración de REC-U4. Caso 1111.

3.7 Generación automática de casos

Una vez seleccionados los casos suficientes para crear una base de conocimiento amplia, los estudios de estabilidad se pueden realizar de manera automática con un programa de simulación adecuado. Esta recomendación se vuelve requisito indispensable para sistematizar la información obtenida a partir de modelos del sistema de varios grados de complejidad, o cuando se tenga que investigar el comportamiento del sistema ante futuros cambios de topología.

Es deseable también automatizar el procesamiento de los resultados de los estudios de estabilidad, desde la selección y extracción de las variables de interés, hasta la formación de los patrones de entrada-salida para entrenamiento y prueba.

Ya que se pretende realizar una gran cantidad de casos de estabilidad en serie, se recomienda observar ciertas precauciones:

a) Diseñar una nomenclatura adecuada para identificar claramente los archivos de datos a utilizar, la especificación de las fallas, las condiciones de topología de la red, número de generadores, etc., para estar en condiciones de repetir cualquiera de los casos, si es necesario.

b) Respalidar adecuadamente tanto los archivos de datos de la red como los de datos dinámicos.

c) Es recomendable realizar un análisis de los casos base de flujo, así como de las contingencias propuestas. Al simular los casos base de flujos de predisturbio se debe buscar que no ocurran casos de no convergencia. Si los hay, se deben señalar y evitar utilizarlos o prever que al presentarse no se altere o detenga el proceso automático. Si ocurren casos de contingencia sin convergencia, también se deben marcar, para prestar más atención al resultado de la simulación de estabilidad.

d) Prever que la memoria utilizada por los archivos de resultados generados no exceda la capacidad de la máquina, o incorporar al proceso automático la extracción de únicamente las variables de interés.

e) Realizar al menos un ciclo de simulación observando enseguida los resultados obtenidos, para verificar que la simulación se realiza de acuerdo a las especificaciones, con la finalidad de minimizar errores en el proceso.

3.8 Utilización del simulador SISP

Tanto los estudios de estabilidad que se mencionan en la sección 3.4, como los casos base de flujos, con los que se obtiene la condición inicial se obtuvieron con la ayuda del simulador interactivo de sistemas de potencia (SISP), instalado en una computadora PRIME 2350. La manipulación posterior de los resultados se efectuó en una computadora personal PC-486.

CAPITULO IV

ARQUITECTURAS DE REDES DE NEURONAS ARTIFICIALES PARA LA EVALUACION DE LA ESTABILIDAD TRANSITORIA

4.1 Introducción

En este capítulo se presentan los puntos más importantes a considerar en el diseño de un sistema basado en redes de neuronas artificiales. El desarrollo se realiza en base al problema de interés, resaltando sin embargo los aspectos más generales.

El problema que el sistema de RNA's debe resolver se divide en dos etapas: En la primera debe ser capaz de clasificar correctamente los casos estables/inestables de entrenamiento generados fuera de línea. En la segunda etapa se cuestiona su capacidad de generalización, por medio de la presentación de patrones nuevos no incluidos en el grupo de entrenamiento.

Los patrones de entrada-salida de entrenamiento y de prueba se obtienen a partir de los resultados de las simulaciones de estabilidad detalladas en el capítulo III.

Se presentan las consideraciones que definen las características del algoritmo de aprendizaje, para el problema de clasificación de patrones estables e inestables.

Se estudia el desempeño de RNA's en las que la variable de salida es un indicador de la estabilidad del sistema eléctrico. El índice se deriva heurísticamente y

se expresa por medio de una función discreta o continua en la que intervienen diferentes variables electromecánicas, siendo la diferencia angular el factor más importante.

Se analiza el comportamiento de cuatro variantes de la arquitectura básica, en capas, de RNA's con procesamiento progresivo, que surgen al plantear diferentes formas de expresar el índice de estabilidad. Se compara el desempeño de redes con una y con dos capas internas, provistas de uno, dos o tres elementos de procesamiento en la última capa.

4.2 Características Generales

Una vez que se decide aplicar la técnica de RNA a un determinado problema, se plantean una serie de cuestiones que surgen debido a la multiplicidad de posibilidades existentes. En la selección de algunas de estas alternativas es necesario emplear un razonamiento de tipo heurístico. Esto es, realizar experimentos y observar los resultados, para elegir entonces la mejor opción.

Las preguntas que se deben contestar en las diferentes etapas de diseño y prueba de un sistema basado en RNA's tienen que ver con la arquitectura de la red, con el algoritmo de aprendizaje y con la capacidad de la red. Durante la etapa de implementación surgen preguntas referentes a las características del equipo disponible [21]. Algunas de estas consideraciones son las siguientes:

Arquitectura de la RNA - Se utilizará una arquitectura de procesamiento progresivo, adecuada para resolver problemas del tipo de clasificación, por medio de un algoritmo supervisado.

Número de capas en la RNA - Se probará el desempeño de redes con una o dos capas internas.

se expresa por medio de una función discreta o continua en la que intervienen diferentes variables electromecánicas, siendo la diferencia angular el factor más importante.

Se analiza el comportamiento de cuatro variantes de la arquitectura básica, en capas, de RNA's con procesamiento progresivo, que surgen al plantear diferentes formas de expresar el índice de estabilidad. Se compara el desempeño de redes con una y con dos capas internas, provistas de uno, dos o tres elementos de procesamiento en la última capa.

4.2 Características Generales

Una vez que se decide aplicar la técnica de RNA a un determinado problema, se plantean una serie de cuestiones que surgen debido a la multiplicidad de posibilidades existentes. En la selección de algunas de estas alternativas es necesario emplear un razonamiento de tipo heurístico. Esto es, realizar experimentos y observar los resultados, para elegir entonces la mejor opción.

Las preguntas que se deben contestar en las diferentes etapas de diseño y prueba de un sistema basado en RNA's tienen que ver con la arquitectura de la red, con el algoritmo de aprendizaje y con la capacidad de la red. Durante la etapa de implementación surgen preguntas referentes a las características del equipo disponible [21]. Algunas de estas consideraciones son las siguientes:

Arquitectura de la RNA - Se utilizará una arquitectura de procesamiento progresivo, adecuada para resolver problemas del tipo de clasificación, por medio de un algoritmo supervisado.

Número de capas en la RNA - Se probará el desempeño de redes con una o dos capas internas.

Número de elementos en cada capa - Los elementos de las capas de entrada y de salida quedan definidos por el planteamiento del problema. El número de elementos en las capas internas se definirá heurísticamente, estudiándose el comportamiento de redes con uno a diez elementos en las capas internas.

Interconexión de elementos - Todos los elementos de una misma capa se conectarán con los de la capa siguiente, pero no entre sí. Esto tiene relación con el algoritmo de aprendizaje seleccionado.

Funciones de activación - Se utilizarán funciones de activación del tipo continuo, sigmoideal y unipolar, adecuadas para efectuar mapeos no lineales.

Tipo de actualización de ponderaciones - Para mejorar la rapidez del algoritmo se utiliza una actualización síncrona simultánea. En este caso no interesa una simulación cercana a los procesos físicos, en las que se emplean procesos de actualización asíncronos y estocásticos.

Número total de elementos - Se responderá de acuerdo al desempeño de la RNA.

Algoritmo de aprendizaje - Se utilizará el algoritmo de retropropagación de error, por ser adecuado para un tipo de aprendizaje supervisado y de clasificación.

Número de patrones de entrenamiento - Se utilizarán todos los generados por los estudios de estabilidad. 448 patrones de entrenamiento y 88 patrones de prueba por cada RNA.

Número de iteraciones de aprendizaje - Se fijará un número máximo de iteraciones, para asegurar la finalización del algoritmo de entrenamiento.

Capacidad de aprendizaje de la RNA - Se responderá a esta pregunta conforme

a los resultados que se obtengan.

Capacidad de generalización - Se medirá el desempeño de la red, una vez que se le haya entrenado, por medio de la presentación de casos nuevos.

Implementación física de la RNA - Aquí intervienen aspectos de la constitución física del equipo (hardware), las características de los diferentes tipos de implementación, y la comparación red "real" vs red simulada. [2,40].

4.2.1 Variables de entrada

Las variables que es posible elegir, para formar parte de los patrones de entrada se pueden separar en variables de estado estable o previas a la falla y variables dinámicas, medidas durante o después de la liberación de la falla. La distinción se realiza en vista de la finalidad que se persiga. Las variables previas a la falla se pueden utilizar para el diseño de sistemas de ayuda en línea con la finalidad de prevenir la ocurrencia de disturbios. Las variables de postfalla pueden ser utilizadas por algún sistema automático que incorpore esta información para efectuar acciones de control que atenuen la gravedad de la contingencia.

Entre las variables previas a la falla se tienen:

1. Potencia activa inicial generada,
2. Potencia reactiva inicial generada
3. Posición angular inicial
4. Número de unidades conectadas en cada voltaje
5. Demanda total del sistema
6. Indicadores de configuración de la red

Es posible obtener otras variables de entrada a partir de los resultados de los estudios de flujos y estabilidad, como por ejemplo: Voltajes en nodos de carga o flujos de potencia activa y reactiva en líneas de transmisión. Además, se podría emplear información referente a las unidades generadoras, como constantes de inercia e indicadores de equipo de control disponible o fuera de servicio. En este caso no se utilizan estas variables, sin embargo, es de esperar que un incremento en cantidad y calidad de la información disponible, aumente la exactitud de la clasificación.

Entre las variables de entrada que se pueden registrar durante o después de liberada la falla están:

1. Potencia activa generada durante la falla
2. Potencia activa de postfalla
3. Derivada de la potencia activa inmediata a la liberación de la falla
4. Potencia reactiva generada durante la falla
5. Potencia reactiva de postfalla
6. Aceleración angular promedio durante la falla
7. Aceleración angular de postfalla
8. Derivada de la aceleración inmediata a la liberación de la falla

Una clasificación de variables de entrada, utilizada en algunas aplicaciones del método de reconocimiento de patrones al analizar la estabilidad transitoria [35] es la siguiente:

- 1) Variables directamente medibles.- Voltajes nodales, flujos de potencia activa y reactiva, potencia generada o de carga, etc.
- 2) Variables calculadas.- Angulos de los voltajes nodales, constantes de inercia y reactancias de unidades, elementos de la matriz jacobiana del sistema, etc.
- 3) Variables lógicas.- Estado de interruptores, relevadores, etc.

4.2.2 Variables de salida

Por lo general, se toman como variables de salida aquellas que ocurren durante el desarrollo dinámico del evento o las que se alcanzan al final del tiempo fijado para el análisis. En este caso, entre las posibles variables de salida se cuentan las siguientes:

1. Potencia activa generada final
2. Derivada de la potencia activa final
3. Potencia reactiva generada final
4. Derivada de la potencia reactiva final
5. Posición angular máxima durante el tiempo de estudio
6. Tiempo al que ocurre el ángulo máximo
7. Posición angular final
8. Velocidad angular final
9. Aceleración final
10. Derivada de la aceleración final

4.3 Caso de estudio: Una red por tipo de falla y voltaje

En la sección 3.4 los casos propuestos para formar los patrones de entrenamiento se agrupan en 6 Tablas, una por cada tipo de falla. Para cada falla se consideran dos demandas diferentes, tres topologías de la red y tres esquemas de generación; lo que da 18 casos. En cada caso se simulan 25 estudios de estabilidad, con lo que se dispone de los resultados de 448 simulaciones para cada falla, (Se eliminan 2 de 450 casos). De cada una de ellas se concluye la estabilidad o inestabilidad de las unidades conectadas en 230 kV y de las unidades conectadas en 400 kV, de acuerdo a algún criterio previamente acordado.

Se propone entonces una primera opción en la que se utilicen 12 RNA's, cada

una especializada en estimar la estabilidad de las unidades conectadas a cada voltaje (230 y 400 kV), para cada falla considerada. La Tabla 4.1 muestra la falla y voltaje que corresponde a cada RNA.

TABLA 4.1
RNA's agrupadas por falla y voltaje

RNA Num.	Descripción de la Falla	Unidades conectadas en
1	Trifásica en REC-230	230
2	Trifásica en REC-400	230
3	Trifásica en FRO-400	230
4	Monofásica en REC-230	230
5	Monofásica en REC-400	230
6	Monofásica en FRO-400	230
7	Trifásica en REC-230	400
8	Trifásica en REC-400	400
9	Trifásica en FRO-400	400
10	Monofásica en REC-230	400
11	Monofásica en REC-400	400
12	Monofásica en FRO-400	400

Por supuesto se pueden idear otras maneras de agrupar la información de los patrones de entrenamiento. Una primera idea a este respecto, sería utilizar una sola

RNA para el manejo de toda la información, sin embargo lo recomendable es precisamente lo contrario: Tratar de reducir la complejidad del problema, dividiéndolo en partes manejables, para aprovechar la capacidad de las RNA's de trabajar en paralelo. Por ejemplo, una opción sería dividir el espacio de generación en 16 sub-espacios, y agrupar los resultados de todas las fallas correspondientes a cada uno de ellos, con lo que se tendrían ahora 16 RNA's para entrenar.

4.3.1 Selección de variables

Las variables de entrada y salida seleccionadas para entrenar a cada RNA son las siguientes:

Variables de entrada:

1. Potencia activa inicial generada por una de las unidades en 230 kV [MW]
2. Potencia reactiva inicial generada por una de las unidades en 230 kV [MVAR]
3. Posición angular inicial de una de las unidades en 230 kV [rad]
4. Indicador del número de unidades conectadas en 230 kV
5. Potencia activa inicial generada por una de las unidades en 400 kV [MW]
6. Potencia reactiva inicial generada por una de las unidades en 400 kV [MVAR]
7. Posición angular inicial de una de las unidades en 400 kV [rad]
8. Indicador del número de unidades conectadas en 400 kV
9. Demanda total del sistema [MW]
10. Indicador de configuración con red completa
11. Indicador de configuración con la LT REC-400-FRO desconectada
12. Indicador de configuración con la LT FRO-400-VDG desconectada

Las variables de entrada fueron normalizadas en el intervalo (-1,1), de acuerdo a los valores mínimo y máximo que se detectaron en los 448 casos correspondientes a cada falla.

Variable de salida

1. Índice de estabilidad

Una variable indicadora de la estabilidad se puede definir arbitrariamente, haciendo intervenir diversos factores, de los cuales el más importante es la posición angular relativa de los generadores. Otras variables a considerar son la velocidad y la aceleración angular de la máquina.

Un criterio sencillo sería elegir simplemente el valor del ángulo al final del periodo de estudio. Ya que el rango de los valores alcanzados para casos estables e inestables es muy amplio, en este caso se deberían elegir elementos de salida lineales en la última capa de la RNA.

Si por otra parte el indicador de estabilidad se normaliza para que su rango de valores sea entre 0 y 1, se pueden utilizar elementos de salida no lineales en la última capa. Además, es deseable hacer intervenir otras variables adicionales al valor angular.

Enseguida se describe la función lógica utilizada para obtener un índice de estabilidad, en función de las siguientes variables de salida:

- a) Posición angular máxima durante el tiempo de estudio (δ_{max}), [Grados]
- b) Tiempo al que ocurre el ángulo máximo ($t_{\delta_{max}}$), [Seg]
- c) Posición angular al final del estudio (δ_{fin}), [Grados]
- d) Velocidad angular al final del estudio (ω_{fin}), [rad/seg]
- e) Aceleración al final del estudio en ($d\omega_{fin}/dt$), [rad/seg²]
- f) Tiempo total de estudio (t_c), [Seg]

El índice de estabilidad, (ind), toma cuatro posibles valores discretos, entre 0 y 1, de acuerdo a las reglas siguientes:

El caso es estable (ind=0) si:

- 1) $\delta_{fin} < 100^\circ$
- 2) $t_{\delta_{max}} < t_e$

El caso es críticamente estable (ind=0.4) si:

- 1) $\delta_{fin} > 100^\circ$
- 2) $t_{\delta_{max}} < t_e$

El caso es críticamente inestable (ind=0.6) si:

- 1) $\delta_{fin} > 100^\circ$
- 2) $t_{\delta_{max}} = t_e$

El caso es inestable (ind=1) si:

- 1) $\delta_{fin} > 100^\circ$
- 2) $t_{\delta_{max}} = t_e$
- 3) $d\omega_{fin}/dt > 0$
- 4) $\omega_{fin} > 1$ [rad/seg]

El caso es inestable (ind=1) si:

- 1) $\delta_{fin} > 150^\circ$

Estos criterios se diseñaron de acuerdo a los resultados observados en los casos de entrenamiento. Como puede observarse, la variable a la que se le da mayor importancia es la diferencia angular comparada con un cierto umbral. Otras variables de interés son el tiempo al que ocurre el valor angular máximo y la tendencia de la diferencia angular (a crecer o disminuir) al final del tiempo de estudio.

4.3.2 Formas de la variable de salida

Salida discreta múltiple.- Suponiendo que se ha llevado a cabo un entrenamiento exitoso de una RNA con los valores del índice de estabilidad dados en 4.3.1, la salida real (continua) de la RNA ante un patrón de entrenamiento o de prueba no será exactamente el valor deseado, sino que se acercará a él con un cierto error. De esta manera, se puede aplicar un criterio de discretización que considere una cierta tolerancia en la evaluación de los resultados. Para obtener una salida discreta múltiple, por ejemplo, la clasificación de los casos se podría establecer como sigue:

El caso es:	Si la salida está entre:
Estable	0 y 0.3
Críticamente estable	0.3 y 0.5
Críticamente inestable	0.5 y 0.7
Inestable	0.7 y 1.0

Salida continua.- Si no se realiza la discretización anterior, el valor de salida se puede interpretar directamente como una medida del grado de estabilidad o inestabilidad, según el resultado esté cercano a cero o a uno respectivamente.

Salida discreta binaria.- El caso de salida discreta múltiple con dos valores límite, da lugar a tener un índice binario, con valores (0, 1) que clasifique los casos simplemente en estables e inestables, agrupando dentro de los casos inestables a los que son críticamente inestables, y dentro de los casos estables a los críticamente estables.

4.3.3 Análisis de los Casos de Entrenamiento y de Prueba

Utilizando los criterios de las secciones 4.3.1 y 4.3.2, las variables de salida de cada estudio de estabilidad se procesan y se contabilizan los casos estables, críticamente estables, críticamente inestables e inestables. La Tabla 4.2 muestra los resultados de

este conteo, realizado para cada grupo de 448 patrones de entrenamiento y 88 patrones de prueba.

TABLA 4.2
Número de Casos por Categoría de Clasificación

Red. Num.	Casos de Entrenamiento				Casos de Prueba			
	Estab.	Crit. Estab.	Crit. Inest.	Inest.	Estab.	Crit. Estab.	Crit. Inest.	Inest.
1	386	2	0	60	73	3	1	11
2	228	3	0	217	21	2	0	65
3	262	4	0	182	28	1	0	59
4	438	8	0	2	87	1	0	0
5	297	4	0	147	44	0	0	44
6	310	0	0	138	50	2	0	36
7	414	2	0	32	76	1	0	11
8	226	1	0	221	18	0	0	70
9	257	1	0	190	28	0	0	60
10	440	0	0	8	87	1	0	0
11	294	2	0	152	43	1	0	44
12	306	0	0	142	49	0	1	38
Total	3858	27	0	1491	604	12	2	438

Con respecto a los patrones de entrenamiento, se observa que no existen casos críticamente inestables y que los casos críticamente estables forman un grupo reducido. De acuerdo a una regla empírica empleada por las técnicas del reconocimiento de patrones [35], el número de patrones de cada clase debería ser al menos diez veces mayor que el número de variables de entrada. En este caso se tienen 12 variables de entrada, con lo que el mínimo número de patrones por clase debería ser de 120. De acuerdo con esto, no pueden esperarse buenos resultados al intentar clasificar los casos críticos.

Además, para las redes 1, 4, 7 y 10 el número de casos inestables es también menor a 120, por lo que en estos casos se supone que también se tendrán dificultades para la clasificación de casos estables/inestables. En las demás redes el número de casos inestables es mayor que 120.

Para aumentar el número de casos inestables a proporcionar a determinada red, se deberían realizar simulaciones adicionales en las regiones de inestabilidad. En este se efectuaron algunos estudios adicionales pero se utilizan sólo para propósitos de prueba, no de entrenamiento.

4.4 Parámetros del proceso de aprendizaje

De acuerdo al tipo de red de neuronas artificiales seleccionado, se tienen los siguientes parámetros disponibles:

1. Número máximo de iteraciones
2. Tolerancia de error
3. Longitud del paso de aprendizaje
4. Número de neuronas en la(s) capa(s) oculta(s)

El número total de iteraciones se puede fijar inicialmente a un número pequeño, para observar el comportamiento general del algoritmo y posteriormente se puede ajustar a un valor mayor para que se cumpla en primer término el criterio de tolerancia de error. En este caso se fija el número de iteraciones en 500.

La tolerancia de error es un criterio que sirve para detener el algoritmo de aprendizaje. Si la suma cuadrática de errores de todos los patrones en determinada iteración es menor que la tolerancia, el algoritmo se detiene. En este caso se le asignó un valor de 0.2 %.

Se pueden utilizar criterios adicionales para detener el algoritmo: Por ejemplo, para asegurar que el valor del error durante el proceso de aprendizaje siempre tienda a disminuir, el algoritmo se puede detener cuando se descubra una tendencia a aumentar de manera sostenida. Además, si se utiliza el error de clasificación de los patrones de prueba como una medida de la capacidad de generalización de la red, y se verifica este valor durante el proceso de aprendizaje, es posible detener el algoritmo en un punto cercano al de mínimo error de prueba, o de máxima generalización, siempre y cuando el error de entrenamiento sea menor a un valor especificado o después de un número de iteraciones prefijado. En este caso se emplea el primer criterio, restringido a aplicarse después de que el error de entrenamiento es menor de 0.2%, el segundo criterio se aplica a partir de la iteración 250.

La longitud del paso de aprendizaje se ajusta de manera automática, reduciendo o aumentando su valor, para mejorar las características de convergencia del algoritmo. Si en la iteración actual (k), la suma cuadrática de error es menor que en la iteración anterior ($k-1$), el valor de la longitud del paso debe aumentarse en cierta proporción. Si, por el contrario, la suma cuadrática de error actual es mayor que en la iteración anterior, la longitud del paso debe disminuir, para dar oportunidad al algoritmo de aprendizaje de volver sobre sus pasos y localizar el mínimo. Los porcentajes de incremento y disminución, recomendados son 10% y 30% respectivamente.

El número de elementos en la capa oculta se fija después de realizar un análisis comparativo de los resultados que se obtengan de una serie de pruebas. Se recomienda realizar inicialmente una serie de pruebas con una red de una capa interna, que a su vez contenga de uno a diez elementos.

Los resultados que se observan en las secciones subsecuentes se obtuvieron utilizando la herramienta de simulación de redes de neuronas artificiales del paquete computacional MATLAB para WINDOWS. En el anexo A.1 se muestra el listado del algoritmo básico de retropropagación de error.

4.5 Arquitecturas de RNA's.

Se estudiarán cuatro variantes de la arquitectura básica de procesamiento progresivo. Para redes con una capa interna se analizará el comportamiento del algoritmo cuando la estimación de estabilidad se obtiene a partir de uno, dos o tres elementos de salida. Para redes con dos capas internas sólo se analiza el caso de tener un elemento de salida. Las salidas finales serán de tipo discreto, con valores cero o uno. Esquemáticamente se tendrán las siguientes opciones:

Redes de una capa interna

Arquitectura A: Un elemento de salida

$$\text{Valor de salida} = \begin{bmatrix} 0 \text{ caso estable} \\ 1 \text{ caso inestable} \end{bmatrix}$$

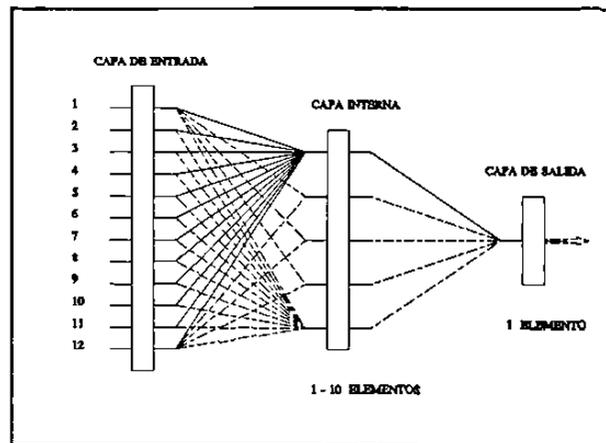


Fig. 4.1 Arquitectura A.

Arquitectura B: Dos elementos de salida.

$$\text{Valores de salida} = \begin{bmatrix} [1,0] \text{ caso estable} \\ [0,1] \text{ caso inestable} \end{bmatrix}$$

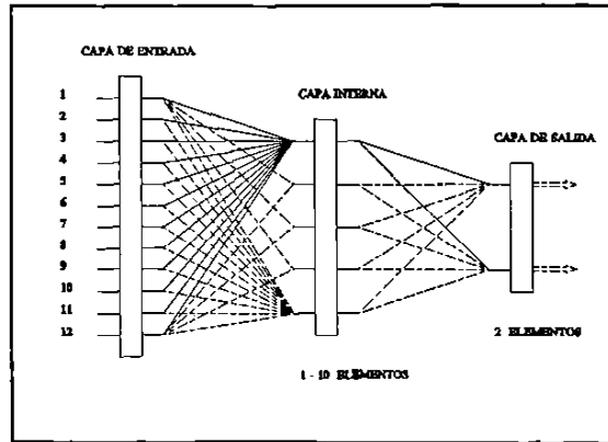


Fig. 4.2 Arquitectura B.

Arquitectura C: Tres elementos de salida.

$$\text{Valores de salida} = \begin{bmatrix} [0,0,0] & \textit{caso estable} \\ [1,0,0] & \textit{crit. estable} \\ [0,1,0] & \textit{crit. inestable} \\ [0,0,1] & \textit{caso inestable} \end{bmatrix}$$

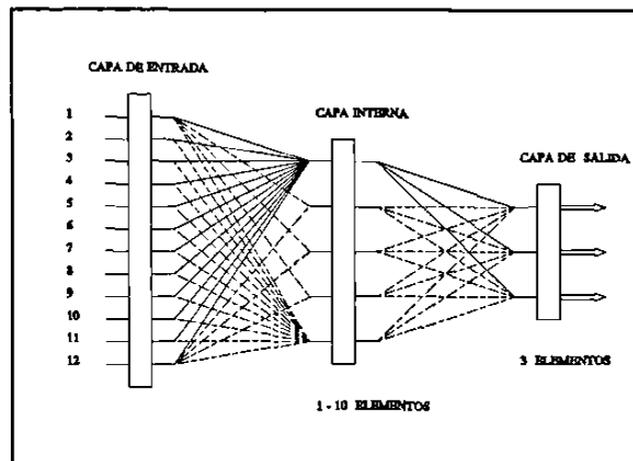


Fig. 4.3 Arquitectura C.

Redes de dos capas internas

Arquitectura D: Un elemento de salida.

$$\text{Valor de salida} = \begin{bmatrix} 0 \text{ caso estable} \\ 1 \text{ caso inestable} \end{bmatrix}$$

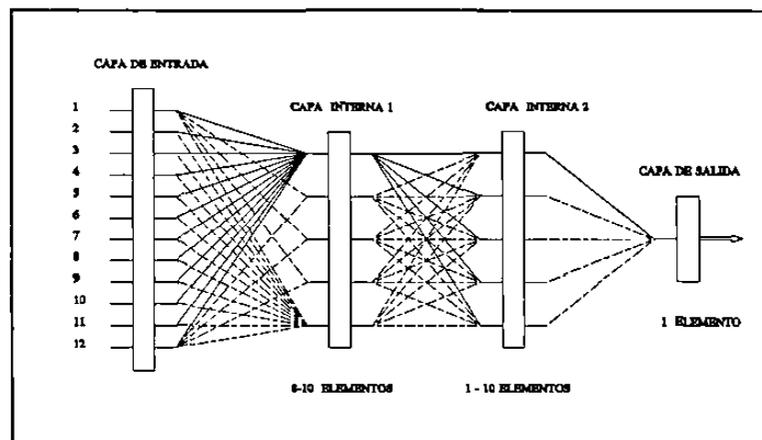


Fig. 4.4 Arquitectura D.

4.5.1 Redes de una capa interna. Arquitectura A.

Se presentan los resultados obtenidos durante el proceso de aprendizaje de los 12 grupos de patrones de entrada-salida, cuando se presentan a redes de neuronas artificiales, en las que se varía el número de elementos en la capa interna de uno a diez.

La Tabla 4.3 muestra el número de iteraciones en el que se detiene el proceso de aprendizaje, por alguno de los criterios mencionados en la sección 4.4. Se observa que, aunque el número máximo de iteraciones se fijó en 500, el mayor número alcanzado fueron 307 iteraciones para la red de la falla cinco, con una neurona en la capa interna, mientras que el caso de convergencia más rápida es de 208 iteraciones, para la red de la falla diez, con ocho neuronas en la capa interna. Sin embargo, en la mayoría de los casos, el aprendizaje se detiene en 251 iteraciones, esto es porque se detecta un mínimo en el error de prueba, antes de esta iteración.

TABLA 4.3
Número de Iteraciones Efectuadas por Cada RNA

RED Num.	Número de Neuronas en la Capa Interna									
	1	2	3	4	5	6	7	8	9	10
1	251	251	251	251	263	251	284	265	224	261
2	251	251	251	251	258	252	255	252	251	252
3	252	251	251	253	281	259	251	272	301	251
4	252	252	245	254	254	251	251	252	252	231
5	307	251	251	254	251	260	258	251	251	262
6	251	251	251	263	251	266	252	261	252	255
7	251	256	252	251	251	251	253	279	252	253
8	254	251	253	252	293	251	251	251	251	251
9	266	251	251	253	252	254	251	252	264	251
10	251	251	253	251	224	251	217	208	251	252
11	251	254	251	251	252	256	275	251	260	251
12	251	251	270	251	251	251	264	251	254	252

En la Tabla 4.4 se muestran los valores alcanzados por la suma cuadrática de error de entrenamiento para cada una de las redes. El error promedio para todas las redes se indica en el último renglón. Se observa que este error disminuye a medida que se aumenta el número de neuronas en la capa interna, hasta alcanzar valores mínimos para las redes con ocho y nueve elementos.

El error máximo es de 1.85% para la red de la falla nueve, con un elemento en la capa interna, mientras que el mínimo error, 0.03%, se obtiene por redes de 4,5,8 y 9 elementos en la capa interna a las que se presentan los patrones de la falla cuatro. El que los errores sean mínimos para esta falla indica que los patrones de entrenamiento se clasifican más fácilmente.

TABLA 4.4
Suma Cuadrática de Errores de Entrenamiento [%]

RED Num.	Número de Neuronas en la Capa Interna									
	1	2	3	4	5	6	7	8	9	10
1	0.29	0.28	0.31	0.26	0.30	0.29	0.23	0.29	0.22	0.26
2	1.70	1.54	1.46	1.26	0.96	1.02	1.13	1.14	0.84	0.94
3	1.46	1.37	1.05	1.11	1.21	0.76	0.99	0.91	0.83	0.99
4	0.04	0.08	0.05	0.03	0.03	0.04	0.06	0.03	0.03	0.04
5	1.05	0.97	0.96	0.96	0.84	0.87	0.93	0.56	0.76	0.89
6	0.91	0.89	0.76	0.49	0.91	0.58	0.79	0.71	0.58	0.63
7	0.59	0.58	0.65	0.58	0.55	0.67	0.59	0.57	0.63	0.58
8	1.55	1.47	1.65	1.29	1.00	0.96	1.07	0.66	0.79	0.83
9	1.85	1.65	1.61	1.15	1.17	1.49	0.79	0.89	1.09	1.20
10	0.27	0.18	0.15	0.22	0.16	0.17	0.20	0.19	0.19	0.20
11	1.03	1.04	1.10	1.04	1.12	1.06	0.99	0.92	0.95	0.99
12	0.66	0.58	0.79	0.59	0.56	0.62	0.63	0.63	0.64	0.50
PROM.	0.95	0.89	0.88	0.75	0.73	0.71	0.70	0.63	0.63	0.67

La Tabla 4.5 contiene los valores de la suma cuadrática de error de prueba, que se alcanzan al final del entrenamiento por redes de uno a diez elementos en la capa interna. En la última fila se indican los valores promedio de error para todas las redes con el mismo número de elementos en la capa interna. Se observa que el mínimo error promedio de prueba se logra por las redes con 10 elementos en la capa interna.

La magnitud de los errores de prueba es, en general, mayor que la de los errores de entrenamiento. Además, se observa que el hecho de obtener errores de entrenamiento reducidos no garantiza que se obtengan errores de prueba pequeños.

TABLA 4.5
Suma Cuadrática de Errores de Prueba [%]

RED Núm.	Número de Neuronas en la Capa Interna									
	1	2	3	4	5	6	7	8	9	10
1	6.16	6.18	6.00	5.97	6.23	6.06	6.33	5.73	6.14	6.04
2	6.70	6.89	7.13	5.45	5.29	5.56	5.76	5.61	4.81	4.65
3	2.55	3.25	3.15	3.06	2.89	2.86	2.54	3.08	3.12	2.57
4	0.17	0.29	0.14	0.14	0.11	0.18	0.18	0.21	0.15	0.13
5	3.09	3.37	3.00	3.15	2.99	3.29	3.09	3.55	3.39	2.97
6	2.43	2.04	2.03	1.70	1.95	1.72	1.71	2.02	1.80	1.69
7	6.73	6.72	6.78	6.89	5.93	6.24	6.76	6.97	5.99	6.47
8	4.68	4.10	4.08	4.33	4.55	4.00	4.25	3.60	4.13	4.12
9	1.81	2.01	1.88	1.74	2.16	2.04	1.98	1.67	1.75	1.89
10	0.74	0.89	0.69	0.72	0.66	0.60	0.69	0.64	0.71	0.73
11	1.72	2.02	1.86	1.62	2.00	1.95	1.64	1.90	1.83	1.98
12	2.16	2.02	2.34	2.26	2.34	2.61	2.42	2.20	2.33	2.21
Prom.	3.25	3.32	3.26	3.09	3.09	3.09	3.11	3.10	3.01	2.95

En la Tabla 4.6 se muestra el número total de patrones clasificados erróneamente por cada red de n elementos en la capa oculta, para cada falla. Considerando como óptimo desempeño un menor número de errores y un menor número de elementos en la capa oculta, se señalan en la Tabla 4.6 con (*) las redes con los errores mínimos en la etapa de entrenamiento. En total se tienen 11 errores de entrenamiento para el grupo de 12 redes, lo que equivale a un error de 0.2%. En la Tabla 4.7 se señalan igualmente los errores de prueba para estas redes. En este caso se tienen 48 patrones mal clasificados en la etapa de prueba, esto es un 4.54% de error.

Si se considera que un óptimo desempeño está dado por un mínimo de errores en la etapa de prueba, el número de casos con error aumenta en la etapa de entrenamiento a 36 casos (0.67%), los que se señalan con (**) en la Tabla 4.6.

TABLA 4.6

Número Total de Clasificaciones Incorrectas en Etapa de Entrenamiento

RED Núm.	Número de Neuronas en la Capa Interna									
	1	2	3	4	5	6	7	8	9	10
1	0 *	0	0	0	0	0	0	0 **	0	0
2	8	6	6	5	3 *	3	4	4	3	3 **
3	10	9	6	9	7	1 *	5 **	3	2	6
4	0 *	0	0	0	0	0	0	0	0	0
5	3 **	4	3	3	3	4	4	0 *	3	2
6	3	4	4	0 *	4	0 **	4	4	1	1
7	4	3	3	4	2 **	2	2	1 *	3	2
8	6	6	6	5 **	4	5	3	2	1 *	2
9	9 **	7	8	6	6	7	1	0 *	4	5
10	0 *	0	0	0	0	0	0	0	0	0
11	7 **	6	6	5	6	5	6	5	4 *	4
12	2	2 **	2	2	1 *	4	2	2	2	1
Total	52	47	44	39	36	29	31	21	23	26

Los casos con mínimo error de prueba también se señalan en la Tabla 4.7 con (**), en total se tienen 38 casos mal clasificados, esto es un 3.60% de error.

Es posible entonces plantear dos alternativas para el diseño de el grupo de 12 redes: Una primera opción en la que el grupo de RNA's esté formado por aquellas que alcanzaron errores mínimos en la etapa de entrenamiento y una segunda opción en la que se seleccionen las redes con el menor número de errores de prueba. El primer grupo de redes se utilizaría para propósitos de interpolación, mientras que la segunda opción sería útil para casos de extrapolación, que se alejan del dominio de los casos de entrenamiento.

TABLA 4.7

Número Total de Clasificaciones Incorrectas en Etapa de Prueba

RED Núm.	Número de Neuronas en la Capa Interna									
	1	2	3	4	5	6	7	8	9	10
1	9 *	9	9	9	9	9	9	8 **	9	9
2	8	7	10	6	8 *	7	7	7	6	5 **
3	3	4	4	4	3	4 *	2 **	4	4	2
4	0 *	0	0	0	0	0	0	0	0	0
5	5 **	5	5	5	5	5	5	5 *	6	5
6	3	2	2	1 *	1	0 **	0	1	0	0
7	8	8	8	9	7 **	8	8	8 *	8	8
8	7	6	6	5 **	7	5	7	5	5 *	5
9	1 **	1	1	1	2	1	2	1 *	1	1
10	1 *	1	1	1	1	1	1	1	1	1
11	2 **	2	2	2	2	2	2	2	2 *	3
12	3	2 **	3	3	4 *	4	4	2	3	4
Total	50	47	51	46	49	46	47	44	45	43

En la Tabla 4.8 se muestra el porcentaje total de patrones clasificados erróneamente, separando los errores en falsas alarmas y en falsos estados estables. Se señalan como falsas alarmas aquellos casos que siendo estables se clasifican como inestables, en las columnas de falso estado estable se encuentran los casos que siendo inestables se clasifican como estables.

El grupo de redes con ocho neuronas en la capa interna es la que obtiene el menor nivel de errores de clasificación en la etapa de entrenamiento, con un error de 0.39 %; mientras que las redes con diez elementos en la capa interna logran el menor porcentaje de casos erróneos en la etapa de prueba: 4.1 % de error.

TABLA 4.8

Porcentaje de Errores de Clasificación. Arquitectura A.

Número de Neuronas en Capa Interna	Casos de Entrenamiento			Casos de Prueba		
	Falsa Alarma	Falso E. E.	Total	Falsa Alarma	Falso E. E.	Total
1	0.52	0.45	0.97	3.1	1.6	4.7
2	0.39	0.48	0.87	2.7	1.7	4.5
3	0.39	0.43	0.82	3.1	1.7	4.8
4	0.39	0.33	0.73	2.6	1.7	4.3
5	0.33	0.33	0.67	2.8	1.8	4.6
6	0.24	0.30	0.54	2.6	1.8	4.4
7	0.32	0.26	0.58	2.7	1.7	4.4
8	0.15	0.24	0.39	2.5	1.7	4.2
9	0.26	0.17	0.43	2.6	1.7	4.3
10	0.26	0.22	0.48	2.5	1.6	4.1

Otra alternativa para obtener un mejor desempeño general sería seleccionar aquellas redes que hubieran obtenido el menor error de entrenamiento promedio.

Considerando que las redes con ocho, nueve y diez elementos son las que logran los errores mínimos de entrenamiento, se eligen de entre ellas las que tienen el menor número de clasificaciones erróneas. Las 12 redes seleccionadas para cada tipo de falla se muestran en la Tabla 4.9, donde se observa que el número total de clasificaciones incorrectas es de 13, (0.24% de error). Sin embargo, el número total de clasificaciones de prueba incorrectas se mantiene en 43, (4.07% de error).

TABLA 4.9

Clasificaciones Incorrectas de Prueba. Arquitectura A.

Red Num. / Neuronas en Capa Interna	Casos de Entrenamiento			Casos de Prueba		
	Falsa Alarma	Falso E. E.	Total	Falsa Alarma	Falso E. E.	Total
1/8	0	0	0	7	1	8
2/10	2	1	3	5	0	5
3/9	1	1	2	1	3	4
4/8	0	0	0	0	0	0
5/8	0	0	0	0	5	5
6/9	1	0	1	0	0	0
7/8	1	0	1	6	2	8
8/9	0	1	1	4	1	5
9/8	0	0	0	0	1	1
10/8	0	0	0	1	0	1
11/9	2	2	4	0	2	2
12/10	1	0	1	2	2	4
TOTAL	8	5	13	26	17	43

En los resultados reportados hasta el momento se considera un umbral de activación de 0.5 en la capa de salida, esto es, si la salida real de la red es menor a 0.5 entonces se le asigna el valor cero (estable), y si el valor de salida real es mayor o igual a 0.5, entonces se le asigna el valor 1 (inestable). En la Tabla 4.10 se reportan los porcentajes totales de error de clasificación para la etapa de prueba, obtenidos por las redes de la Tabla 4.9, cuando se varía el umbral de activación desde 0.1 a 0.9. El caso con un umbral de 0.5 corresponde al detallado en la Tabla 4.9.

TABLA 4.10

Porcentajes Totales de Error de Clasificación. Redes de Tabla 4.9.

Valor del Umbral	Errores de Prueba		
	F.A.	F.E.E.	Total
0.1	8.90	0.09	8.99
0.2	6.63	0.19	6.82
0.3	5.11	0.76	5.87
0.4	4.07	1.14	5.21
0.5	2.46	1.61	4.07
0.6	1.99	2.56	4.54
0.7	1.32	3.22	4.54
0.8	0.66	3.69	4.35
0.9	0.28	5.78	6.06

Se observa que los errores de clasificación del tipo de falso estado estable disminuyen al disminuir el valor del umbral. Sin embargo aumenta el porcentaje de errores del tipo falsa alarma. El menor porcentaje global de error se obtiene con el umbral de 0.5.

Por otra parte, se observa que existe una relación general entre la distribución de casos inestables/estables y los porcentajes de error alcanzados en la etapa de entrenamiento. En la Tabla 4.11 se ordenan los resultados de las últimas 3 columnas de la Tabla 4.4 de acuerdo al valor de la relación número de casos inestables/estables (RCIE), obtenida de la Tabla 4.2.

TABLA 4.11

Errores de Entrenamiento ordenados de acuerdo a RCIE

RED No.	RCIE [%]	Número de Neuronas en Capa Oculta		
		8	9	10
4	0.45	0.03	0.03	0.04
10	1.82	0.19	0.19	0.20
7	7.69	0.57	0.63	0.58
1	15.46	0.29	0.22	0.26
6	44.52	0.71	0.58	0.63
12	46.40	0.63	0.64	0.50
5	48.83	0.56	0.76	0.89
11	51.35	0.92	0.95	0.99
3	68.42	0.91	0.83	0.99
9	73.64	0.89	1.09	1.20
2	93.94	1.14	0.84	0.94
8	97.35	0.66	0.79	0.83

Para los casos extremos (RCIE=0.45, 1.82), donde existen pocos casos inestables se observan valores de error muy pequeños que indican la regularidad de los mapeos. Cuando aumenta el valor de RCIE aumenta el valor promedio de los errores. Los valores de error cercanos a 1% ocurren para los valores de RCIE cercanos al 100%, que indicaría una distribución ideal en la que la mitad de los casos de entrenamiento corresponden a cada una de las clases estable o inestable.

4.5.2 Redes de una capa interna. Arquitectura B.

En este caso se utilizan dos elementos en la capa de salida. La salida [1,0] se considera como un caso estable y la salida [0,1] como un caso inestable. Se presentan los patrones de entrenamiento a diez grupos de RNA's, donde cada grupo tiene desde uno a diez elementos en la capa interna.

En la Tabla 4.12 se muestra el número total de patrones clasificados erróneamente por cada red de n elementos en la capa oculta, para cada falla. Utilizando el criterio de mínimo error de entrenamiento se obtienen las mejores redes y se señalan en la Tabla 4.12 con (*). En total se tienen 18 errores de entrenamiento para el mejor grupo de 12 redes, lo que equivale a un error de 0.33%.

TABLA 4.12

Total de Clasificaciones Incorrectas en Etapa de Entrenamiento. Arquitectura B.

RED Núm.	Número de Neuronas en la Capa Interna									
	1	2	3	4	5	6	7	8	9	10
1	0 *	0	0 **	0	0	0	0	0	0	0
2	8	3 **	5	8	6	2 *	3	6	2	4
3	9	8	9	10	7	7	8	6 **	0 *	3
4	0 *	0	0	0	0	0	0	0	0	0
5	3 *	4	4	3	3	3	3	4	3	3
6	4	4	4	4	4 **	4	4	4	3 *	4
7	3 **	5	6	3	4	4	4	3	2 *	2
8	6 **	4	8	3	2	4	3	1 *	4	2
9	11**	3	2	7	5	9	0 *	8	1	3
10	0 *	0	0	0	0	0	0	0	0	0
11	6 **	5 *	7	7	7	7	7	7	6	7
12	2 *	2	3	2	2	2	2	2	2	2
Total	52	38	48	47	40	42	34	41	23	30

En la Tabla 4.13 se señalan igualmente los errores de prueba para las mismas redes. En este caso se tienen 51 patrones mal clasificados en la etapa de prueba, esto es un 4.83% de error.

Si se considera el criterio de mínimo error de prueba, el número de casos con error en la etapa de entrenamiento es de 44 (0.82%), los que se señalan con (**) en la Tabla 4.12. Los casos con mínimo error de prueba en la etapa de prueba se señalan en la Tabla 4.13 con (*), en total se tienen 41 casos mal clasificados, esto es un 3.88% de error.

TABLA 4.13

Total de Clasificaciones Incorrectas en Etapa de Prueba. Arquitectura B.

RED Núm.	Número de Neuronas en la Capa Interna									
	1	2	3	4	5	6	7	8	9	10
1	10*	9	8 **	8	9	10	8	10	8	9
2	8	6 **	8	10	7	6 *	6	7	7	7
3	3	4	3	3	4	4	4	2 **	5 *	4
4	0 *	0	0	0	0	0	0	0	0	0
5	5 *	5	5	5	5	5	7	5	5	5
6	2	3	1	3	0 **	1	0	0	0 *	0
7	8 **	8	8	8	8	8	8	8	8 *	8
8	5 **	6	7	7	6	6	7	7 *	6	5
9	1 **	3	3	3	3	2	4 *	1	3	2
10	1 *	1	1	1	1	1	1	1	1	1
11	2 **	2 *	2	2	2	2	2	3	2	3
12	3 *	3	4	3	3	3	4	3	3	3
Total	48	50	50	53	48	48	51	47	48	47

La Tabla 4.14 muestra el porcentaje de clasificaciones erróneas obtenidas para los casos de entrenamiento y prueba, separando los errores en falsas alarmas y falsos estados estables. No se observa una disminución apreciable en los porcentajes de error con respecto a los que se reportan en la Tabla 4.8, para las redes que utilizan un solo elemento de salida.

TABLA 4.14

Porcentaje de Errores de Clasificación. Arquitectura B.

Número de Neuronas en Capa Interna	Casos de Entrenamiento			Casos de Prueba		
	Falsa Alarma	Falso E. E.	Total	Falsa Alarma	Falso E. E.	Total
1	0.47	0.50	0.97	2.94	1.61	4.55
2	0.33	0.35	0.71	2.84	1.89	4.73
3	0.33	0.37	0.89	2.75	1.80	4.73
4	0.39	0.39	0.87	3.13	1.61	5.02
5	0.32	0.33	0.74	2.46	1.99	4.54
6	0.37	0.37	0.78	2.75	1.80	4.54
7	0.28	0.24	0.63	2.46	2.08	4.83
8	0.32	0.35	0.76	2.75	1.52	4.45
9	0.22	0.11	0.43	2.46	1.89	4.55
10	0.26	0.17	0.56	2.37	1.89	4.45

También se debe hacer notar que en ocasiones la suma de los errores de falsa alarma y los de falso estado estable es menor que el total de errores encontrado. Esto se debe a que existen casos "indefinidos", esto es, valores de salida que no se especificaron a la red, pero que llegan a ocurrir. Las salidas indefinidas son la [0,0] y la [1,1].

Definiendo arbitrariamente la salida [0,0] como un caso estable y la salida [1,1], como un caso inestable, se pueden clasificar los casos indefinidos, tanto de entrenamiento como de prueba, y evaluar si es correcta la asignación. Los resultados de este proceso se observan en la Tabla 4.15. En total se tiene 46 casos de entrenamiento, de los cuales 29 se clasifican bien y 17 mal, con respecto a los casos de prueba se mantiene la proporción, pues de 15 casos indefinidos, 9 se clasifican correctamente y 6 no están bien clasificados.

TABLA 4.15
Clasificaciones Indefinidas. Arquitectura B.

Número de Neuronas en Capa Interna	Casos de Entrenamiento			Casos de Prueba		
	Error	Bien	Total	Error	Bien	Total
1	0	0	0	0	0	0
2	1	0	1	0	0	0
3	0	10	10	1	1	2
4	4	1	5	0	3	3
5	2	3	5	0	1	1
6	2	0	2	0	0	0
7	1	5	6	2	1	3
8	3	2	5	1	1	2
9	1	4	5	0	2	2
10	3	4	7	2	0	2

Aún cuando se excluyan los casos indefinidos correctamente clasificados de el total de casos con error, no se obtienen menores errores que cuando se utiliza un solo elemento de salida.

4.5.3 Redes de una capa interna. Arquitectura C.

Ahora se tienen tres elementos en la capa de salida. En este caso se presentan explícitamente los patrones de salida definidos como casos críticamente estables y críticamente inestables, además de los casos estables e inestables. Al igual que para las arquitecturas A y B, se investiga el funcionamiento de redes con uno a diez elementos en la capa interna.

En la Tabla 4.16 se muestra el número total de patrones clasificados erróneamente por cada red y para cada falla. Se señalan en la Tabla 4.16 con (*) las redes con los errores mínimos en la etapa de entrenamiento. En total se tienen 28 errores de entrenamiento para el mejor grupo de 12 redes, lo que equivale a un error de 0.52%.

TABLA 4.16

Total de Clasificaciones Incorrectas en Etapa de Entrenamiento. Arquitectura C.

RED Núm.	Número de Neuronas en la Capa Interna									
	1	2	3	4	5	6	7	8	9	10
1	2 *	2 **	4	3	2	2	2	2	2	2
2	9	5	6	7	3 *	5	4 **	6	5	4
3	13	10	4 *	6	5	4	4	5 **	4	5
4	5 **	5	3	2	0 *	3	2	1	3	2
5	7 **	5	7	9	5	4 *	4	4	4	5
6	4	4 **	4	4	4	2	4	4	1 *	1
7	5	5	7	5	4	3 *	5	5	4	5
8	7	7	4 *	4	4	5 **	4	2	4	6
9	10**	7	3	6	7	5	3	8	5	1 *
10	0 *	0	0	0	0	0	0	0	0	0
11	8	6	7 **	8	7	7	5	6	6	4 *
12	2 *	2	2	2	2	2	2	2	2	2
Total	72	58	51	56	43	42	39	45	40	37

En la Tabla 4.17 se señalan igualmente los errores de prueba para estas redes. Se obtienen 57 patrones mal clasificados en la etapa de prueba, esto es un 5.4% de error.

Utilizando el criterio de mínimo de error en la etapa de prueba, el número de casos con error en la etapa de entrenamiento es de 54 casos (1.0%), los que se señalan con (**) en la Tabla 4.16. Los casos de prueba se señalan igualmente en la Tabla 4.17, en total se tienen 46 casos mal clasificados, esto es un 4.36% de error.

TABLA 4.17

Total de Clasificaciones Incorrectas en Etapa de Prueba. Arquitectura C.

RED Núm.	Número de Neuronas en la Capa Interna									
	1	2	3	4	5	6	7	8	9	10
1	12 *	11 **	11	12	11	12	12	11	13	12
2	8	6	7	8	8 *	8	5 **	5	5	8
3	5	5	5 *	5	5	5	5	4 **	5	6
4	0 **	0	3	2	2 *	1	3	2	1	2
5	5 **	5	5	5	6	6 *	5	5	5	7
6	3	2 **	2	2	3	2	2	2	2 *	2
7	8	8	8	8	9	7 *	8	8	8	8
8	6	7	6 *	6	6	5 **	7	7	5	7
9	1 **	1	3	3	2	1	1	1	2	2 *
10	1 *	1	1	1	1	1	1	1	1	1
11	3	3	2 **	3	3	3	3	3	3	3 *
12	3 **	4	4	4	4	4	4	5	4	4
Total	55	53	57	59	60	55	56	54	54	62

La Tabla 4.18 muestra el porcentaje de clasificaciones erróneas obtenidas para los casos de entrenamiento y de prueba, para cada grupo de redes con un número fijo de elementos en la capa interna, separando los errores en falsa alarma (casos estables clasificados como inestables), falso estado estable (casos inestables clasificados como

estables) y combinados (casos críticamente estables clasificados como críticamente inestables o inestables y casos críticamente inestables clasificados como críticamente estables o estables). Debido a las definiciones de los casos críticos, se disminuye el número de casos indefinidos, presentándose solamente 3 resultados de este tipo, uno en cada uno de los grupos de redes de 8, 9 y 10 elementos en la capa interna. Por otra parte, la inclusión de los casos críticos representa mayores exigencias en cuanto a la capacidad de resolución de las redes, con la misma cantidad de información, lo que repercute en una mayor cantidad de errores de clasificación.

TABLA 4.18

Porcentaje de Errores de Clasificación. Arquitectura C.

Número de Neuronas en Capa Interna	Casos de Entrenamiento				Casos de Prueba			
	Falsa Alarma	Falso E. E.	Comb.	Total	Falsa Alarma	Falso E.E.	Comb.	Total
1	0.50	0.48	0.35	1.34	2.84	1.70	0.66	5.21
2	0.32	0.41	0.35	1.08	2.75	1.61	0.66	5.02
3	0.22	0.39	0.33	0.95	2.56	1.80	1.04	5.40
4	0.32	0.41	0.32	1.04	2.65	1.99	0.95	5.59
5	0.24	0.24	0.32	0.80	2.75	1.99	0.95	5.68
6	0.19	0.28	0.32	0.78	2.65	1.70	0.85	5.21
7	0.19	0.24	0.30	0.73	2.56	1.70	1.04	5.30
8	0.19	0.32	0.32	0.84	2.65	1.61	0.85	5.11
9	0.19	0.22	0.32	0.74	2.46	1.80	0.85	5.11
10	0.17	0.19	0.32	0.69	3.03	1.99	0.85	5.87

Comparando los porcentajes de error para los mejores grupos de redes con los criterios de mínimo error de entrenamiento y de prueba, que se resume en la Tabla 4.19, se concluye que no es necesario utilizar más de un elemento de salida, si se desea una separación simple de casos estables e inestables.

Tabla 4.19
Porcentaje de Error en Redes de Una capa Interna

Arquitectura	Criterio de Mínimo Error en Etapa de Entrenamiento		Criterio de Mínimo Error en Etapa de Prueba	
	Entrenamiento	Prueba	Entrenamiento	Prueba
A	0.20	4.54	0.67	3.60
B	0.33	4.83	0.82	3.88
C	0.52	5.40	1.00	4.36

4.6 Redes de dos capas internas

Para evaluar el comportamiento de RNA's de dos capas internas, se realizan tres series de pruebas. Tomando en cuenta los resultados obtenidos en la sección 4.5, donde el mejor desempeño global para grupos de redes con el mismo número de elementos en la capa interna se observa en aquellas con ocho, nueve y diez elementos, se plantea estudiar tres variantes de la arquitectura D, donde en la primera capa se colocarán ocho, nueve o diez elementos, mientras que en la segunda capa se tendrán de uno a diez. La Tabla 4.20 muestra el porcentaje de patrones de entrenamiento y de prueba clasificados erróneamente por RNA's de dos capas internas, con ocho elementos en la primera de ellas. Los casos con error se separan en falsas alarmas y falsos estados estables.

TABLA 4.20

Porcentaje de Errores de Clasificación en Redes de dos Capas
Primera Capa Interna de ocho elementos

Número de Neuronas en Segunda Capa Interna	Casos de Entrenamiento			Casos de Prueba		
	Falsa Alarma	Falso E. E.	Total	Falsa Alarma	Falso E. E.	Total
1	0.37	0.39	0.76	2.84	1.61	4.45
2	0.35	0.39	0.74	2.93	1.99	4.92
3	0.28	0.32	0.60	2.84	1.61	4.45
4	0.28	0.32	0.60	2.56	1.80	4.36
5	0.39	0.26	0.65	2.94	1.99	4.92
6	0.37	0.26	0.63	3.12	1.99	5.11
7	0.32	0.35	0.67	2.93	1.61	4.55
8	0.28	0.26	0.54	2.75	1.70	4.45
9	0.37	0.43	0.80	3.03	2.08	5.11
10	0.35	0.35	0.71	3.22	1.89	5.11

Empleando el criterio de mínimo error de entrenamiento, la selección de las mejores redes en este caso reduce el número de errores de entrenamiento a 11 (0.20%) y de prueba a 54 (5.11%). De acuerdo al criterio de mínimo error de prueba, se obtienen 37 errores de entrenamiento (0.69%), y 38 errores en la etapa de prueba (3.60%).

En la Tabla 4.21 se muestran los porcentajes de error de clasificación, en entrenamiento y prueba, para RNA's de dos capas, con nueve elementos en la primera capa interna. Por el criterio de mínimo error de entrenamiento se obtienen 15 errores de clasificación durante el entrenamiento (0.28%) y 45 errores en la etapa de prueba (4.26%). Si se utiliza el criterio de mínimo error de prueba, se tienen 27 errores para la etapa de entrenamiento (0.50%), y 34 errores para la etapa de prueba (3.22%).

TABLA 4.21

Porcentaje de Errores de Clasificación en Redes de dos Capas
Primera Capa Interna de nueve elementos

Número de Neuronas en Segunda Capa Interna	Casos de Entrenamiento			Casos de Prueba		
	Falsa Alarma	Falso E. E.	Total	Falsa Alarma	Falso E. E.	Total
1	0.26	0.26	0.52	2.46	1.80	4.45
2	0.30	0.30	0.60	2.93	1.99	4.92
3	0.33	0.30	0.63	2.84	1.61	4.45
4	0.30	0.30	0.60	2.84	1.70	4.55
5	0.33	0.47	0.80	3.03	1.80	4.83
6	0.32	0.28	0.60	2.46	1.89	4.36
7	0.20	0.32	0.52	2.94	1.70	4.64
8	0.33	0.32	0.65	2.75	1.99	4.73
9	0.33	0.47	0.80	2.94	1.70	4.64
10	0.37	0.32	0.69	2.94	1.33	4.26

La Tabla 4.22 contiene el porcentaje de errores de clasificación de patrones de entrenamiento y de prueba para RNA's de dos capas internas, con diez elementos en la primera de ellas.

Seleccionando las redes que ofrecen el menor número de errores en la etapa de entrenamiento se logra reducir su número a 13 (0.24%) en el entrenamiento y se obtienen 50 errores de prueba (4.73%). Si se utiliza el criterio de errores mínimos de prueba, se obtienen 30 errores en la etapa de entrenamiento (0.56%), y 38 errores de prueba (3.60%).

TABLA 4.22

Porcentaje de Errores de Clasificación en Redes de dos Capas
Primera Capa Interna de diez elementos

Número de Neuronas en Segunda Capa Interna	Casos de Entrenamiento			Casos de Prueba		
	Falsa Alarma	Falso E. E.	Total	Falsa Alarma	Falso E. E.	Total
1	0.32	0.17	0.48	2.94	2.08	5.02
2	0.39	0.35	0.74	2.56	2.08	4.64
3	0.20	0.26	0.47	2.65	1.80	4.45
4	0.39	0.39	0.78	2.94	1.80	4.73
5	0.33	0.30	0.63	2.94	1.80	4.73
6	0.30	0.33	0.63	3.13	1.70	4.83
7	0.30	0.37	0.67	3.03	1.80	4.83
8	0.32	0.35	0.67	3.31	1.61	4.92
9	0.39	0.28	0.67	3.22	1.80	5.02
10	0.22	0.32	0.54	2.84	1.80	4.64

Los porcentajes de error para los mejores grupos de redes, con dos capas internas, de acuerdo con los criterios de mínimo error de entrenamiento y de prueba, se muestran en la Tabla 4.23.

Tabla 4.23

Porcentaje de Error en Redes de Dos capas Internas

Número de Elementos en Primera capa	Criterio de Mínimo Error en Etapa de Entrenamiento		Criterio de Mínimo Error en Etapa de Prueba	
	Entrenamiento	Prueba	Entrenamiento	Prueba
8	0.20	5.11	0.69	3.60
9	0.28	4.26	0.50	3.22
10	0.24	4.73	0.56	3.60

4.7 Aplicación de la Metodología de Superficie de Respuesta

En esta sección se presentan resultados de la aplicación de la metodología de superficie de respuesta (SR), al problema de clasificación de los patrones de prueba, cuando la salida se expresa como una variable binaria discreta (0 - estable, 1 - inestable).

Se proponen y prueban 15 diferentes funciones que expresan el índice de estabilidad en función de tres variables principales: La generación de las unidades conectadas a 230 kV, la generación de las unidades conectadas a 400 kV y la demanda total del sistema. Los patrones de entrenamiento se utilizan para generar los diseños factoriales 2^3 necesarios para cada patrón de prueba. Considerando dos niveles para cada una de las variables normalizadas, se generan diseños en forma cúbica. La Figura 4.5 muestra un ejemplo del cubo generado. Los patrones de prueba consisten de tres puntos, localizados sobre un eje paralelo a la coordenada de la demanda, al centro del cuadrado formado por los ejes de las potencias generadas.

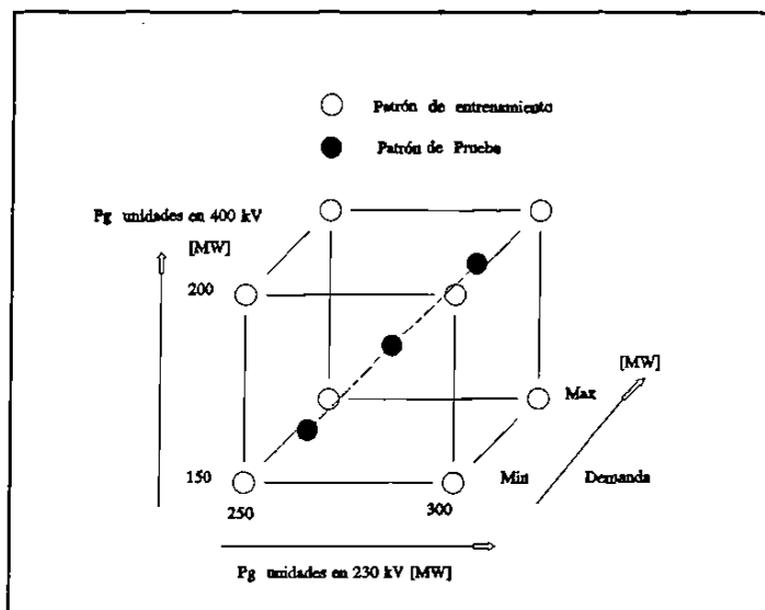


Fig. 4.5 Ejemplo de diseño factorial 2^3 .

4.7.1 Funciones de aproximación propuestas

Se proponen 15 formas de expresar la relación entre las tres variables principales, para probar la capacidad de discriminación que se alcanza con cada una de ellas. Se utilizan funciones con términos lineales y no lineales, y para facilitar la escritura de las funciones se empleará la siguiente notación:

X_0 - Término constante = 1

X_1 - Potencia activa generada por una de las unidades conectadas a 230 kV

X_2 - Potencia activa generada por una de las unidades conectadas a 400 kV

X_3 - Demanda total del sistema

Ordenando las funciones propuestas de acuerdo al número de términos incluidos en la expresión, se tiene la siguiente lista:

- 1 Caso 3A - $F_{est} = X_1 + X_2 + X_3$
- 2 Caso 4A - $F_{est} = X_0 + X_1 + X_2 + X_3$
- 3 Caso 4B - $F_{est} = X_0 + \exp(X_1) + \exp(X_2) + \exp(X_3)$
- 4 Caso 4B - $F_{est} = X_0 + \exp(X_1) + \exp(X_2) + X_3$
- 5 Caso 5A - $F_{est} = X_0 + X_1 + X_2 + X_3 + (X_1 X_2)$
- 6 Caso 5B - $F_{est} = X_0 + X_1 + X_2 + X_3 + (X_1 X_3)$
- 7 Caso 5C - $F_{est} = X_0 + X_1 + X_2 + X_3 + (X_2 X_3)$
- 8 Caso 5D - $F_{est} = X_0 + X_1 + X_2 + X_3 + (X_1 X_3 X_4)$
- 9 Caso 5E - $F_{est} = X_0 + \exp(X_1) + \exp(X_2) + X_3 + (\exp(X_1) \exp(X_2))$
- 10 Caso 5F - $F_{est} = X_0 + \exp(X_1) + \exp(X_2) + X_3 + (\exp(X_1) \exp(X_2) X_3)$
- 11 Caso 7A - $F_{est} = X_0 + X_1 + X_2 + X_3 + (X_1 X_2) + (X_1 X_3) + (X_2 X_3)$
- 12 Caso 7B - $F_{est} = X_0 + X_1 + X_2 + X_3 + (X_1 X_2) + (X_1 X_3) + (X_1 X_2 X_3)$
- 13 Caso 7C - $F_{est} = X_0 + X_1 + X_2 + X_3 + (X_1 X_2) + (X_2 X_3) + (X_1 X_2 X_3)$
- 14 Caso 7D - $F_{est} = X_0 + X_1 + X_2 + X_3 + (X_1 X_3) + (X_2 X_3) + (X_1 X_2 X_3)$
- 15 Caso 8A - $F_{est} = X_0 + X_1 + X_2 + X_3 + (X_1 X_2) + (X_1 X_3) + (X_2 X_3) + (X_1 X_2 X_3)$

4.7.2 Resultados globales por función

La Tabla 4.25 muestra el porcentaje de error de clasificación que se obtiene al procesar los patrones de prueba con el método de superficie de respuesta, separados en falsas alarmas y falsos estados estables. En la última columna se muestran los porcentajes de error total.

Tabla 4.25
Porcentaje de Error de Clasificación
en Etapa de Prueba

CASO	Falsas Alarmas	Falso E. E.	Porcentaje de error
3A	4.36	5.30	9.66
4A	4.26	3.03	7.29
4B	3.50	5.02	8.52
4C	2.27	4.36	6.63
5A	4.26	3.03	7.29
5B	3.79	3.03	6.82
5C	3.79	3.03	6.82
5D	4.26	3.03	7.29
5E	2.27	4.36	6.63
5F	1.23	4.64	5.87
7A	3.31	3.22	6.53
7B	3.60	3.13	6.72
7C	3.41	2.94	6.34
7D	3.12	3.22	6.34
8A	3.31	3.41	6.72

Se observa que la función no lineal que logra el mínimo porcentaje total de

errores es la que posee cinco términos, y donde las variables de generación se modifican por medio de funciones de comportamiento exponencial.

La Tabla 4.26 muestra el número de errores totales que se obtienen para cada una de las 12 fallas en cada caso.

Tabla 4.26
Número de errores totales por falla y caso

CASO	FALLA NUMERO											
	1	2	3	4	5	6	7	8	9	10	11	12
3A	15	16	9	0 *	9	7	8	13	7	1	7	10
4A	12	14	8	0	6 *	2	8	11	6	1	4 *	5
4B	8 *	14	11	0	7	5	7 *	13	10	0 *	7	8
4C	10	11	8	0	8	0 *	7	8	8	1	6	3 *
5A	12	14	8	0	6	2	8	11	6	1	4	5
5B	12	13	7	0	6	2	8	9	5	1	4	5
5C	12	14	7	0	6	2	7	9	5	1	4	5
5D	12	16	7	0	6	2	8	11	5	1	4	5
5E	10	11	8	0	8	0	7	8	8	1	6	3
5F	10	9 *	6	0	8	0	7	4 *	7	0	8	3
7A	13	14	6	0	6	2	7	7	4	1	4	5
7B	12	14	7	0	6	2	7	8	5	1	4	5
7C	13	13	5 *	0	6	2	7	8	3 *	1	4	5
7D	12	13	6	0	6	2	7	7	4	1	4	5
8A	15	14	6	0	6	2	7	7	4	1	4	5

Se señalan en la tabla 4.26 con (*) los casos de clasificación en que se obtienen el mínimo número de errores. El grupo de 12 funciones seleccionadas para dar el mínimo error de prueba reduce el número total de errores a 49, lo que equivale a un 4.64% de error de clasificación.

4.8 Sistema Híbrido RNA's - SR

Tanto si se aplica el método de redes de neuronas artificiales, como el de superficie de respuesta, no se obtiene un 100% de clasificaciones exitosas, sino que se tiene un grupo consistente de patrones en los que fallan ambas metodologías. Si se utilizan ambas técnicas en paralelo, sería posible disminuir las posibilidades de obtener una clasificación errónea, empleando cada metodología en la región del espacio de patrones de prueba en que cada una obtiene los mejores resultados. El desempeño de un sistema híbrido de este tipo sería mejor mientras más diferentes fueran los conjuntos de patrones de prueba en los que cada método falla. En la Tabla 4.27 se listan los patrones que se clasifican erróneamente por el grupo de RNA's de una capa interna con 8 elementos, y por un conjunto de 12 funciones del tipo 5F, diseñadas con el método SR.

Tabla 4.27

Comparación del Número de errores totales

FALLA	RNA	S R	Coincidentes
1	8	10	1
2	7	9	2
3	4	6	1
4	0	0	0
5	5	8	5
6	1	0	0
7	8	7	4
8	5	4	1
9	1	7	0
10	1	0	0
11	2	8	2
12	2	3	2
Total	44	62	18

Al aplicar los dos métodos en paralelo, los patrones clasificados erróneamente por uno de ellos, serían bien clasificados por el otro método, siempre y cuando no cayeran dentro de la columna de los patrones coincidentes, donde ambos métodos fallan. El número de patrones coincidentes en este caso es de 18, lo que indica un 1.70% de error de clasificación.

CAPITULO V

ALTERNATIVAS PARA LA APLICACION DE RNA's

5.1 Introducción

En este capítulo se describen alternativas de aplicación de las RNA's al problema de estimación del nivel de seguridad. Se investigan formas diferentes de presentar los patrones de entrada-salida, así como la utilización de otras variables de salida, además del índice de estabilidad basado en diferencias angulares.

Se propone en primer lugar reorganizar la manera de presentar los patrones de entrenamiento, en lo que se ha llamado subespacios de generación. Se analizan las ventajas o desventajas que representa para un sistema basado en RNA's el emplear esta forma de presentación.

Se estudia el desempeño de las RNA's al utilizar como variables de salida los valores que toman la potencia generada y defasamiento angular al final del período de estudio, analizando gráficamente el comportamiento de estas variables para los casos de entrenamiento. Se propone un nuevo índice de estabilidad basado en el comportamiento de la potencia generada en el tiempo.

Finalmente se analiza la ampliación de la base de datos de entrenamiento, con la inclusión de casos de estabilidad en los que es necesaria la operación de un tipo de control discreto para mejorar el comportamiento dinámico del sistema eléctrico.

5.2 Una Red por cada Subespacio de Generación

La Figura 5.1 muestra las 16 regiones (subespacios) en los que se puede dividir el área que se ha denominado espacio de generación.

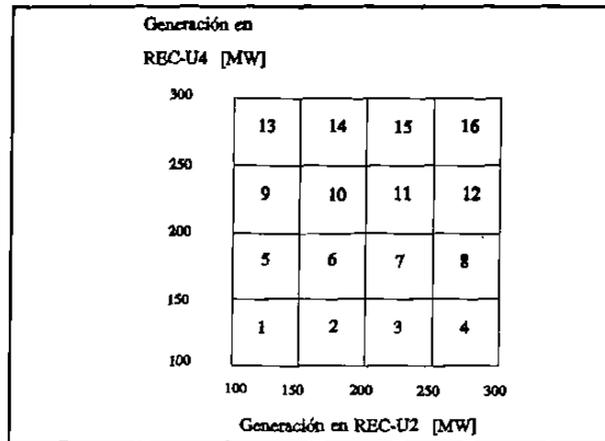


Fig. 5.1 Subespacios de Generación.

Se puede observar que cada subespacio de generación es un cuadrado, donde en cada arista se han efectuado 108 estudios de estabilidad diferentes. Si se consideran los casos de entrenamiento descritos en el capítulo III, en cada esquina del cuadrado se ha variado la localización y el tipo de la falla (6 alternativas), el número de generadores conectados a la red (3), la demanda (2) y la topología del sistema (3), manteniendo constante la generación de las unidades conectadas a la planta. Esto es, para cada subespacio de generación se tiene un total de 432 patrones entrada-salida de entrenamiento.

Se emplean los patrones de prueba listados en las tablas 3.9 a 3.14 del capítulo III, por lo que no se tienen patrones de prueba para todos los subespacios de generación. En los subespacios de generación donde no se tienen patrones de prueba solo se medirá el desempeño de acuerdo a los resultados del proceso de entrenamiento. Por otra parte, el número de patrones de prueba disponibles para cada subespacio de generación es diferente, debido a que varía el número de puntos de prueba que cada subespacio puede abarcar. Los patrones de los puntos de prueba localizados en los

límites de dos subespacios de generación se prueban desde ambos. En la Tabla 5.1 se muestra el número de patrones de prueba disponibles para cada subespacio de generación. Los subespacios no incluidos no tienen patrones de prueba disponibles.

Tabla 5.1

Patrones de Prueba por Subespacio

Subespacio Num.	Num. de Patrones de Prueba disponibles
7	54
8	54
10	54
11	270
12	108
14	54
15	108
16	54

Los patrones de entrada-salida de entrenamiento y de prueba correspondientes a cada subespacio de generación se utilizan para entrenar y probar el desempeño de 32 RNA's. De ellas, 16 corresponden al comportamiento de las unidades conectadas a la barra de 230 kV, mientras que otras 16 RNA's se utilizan para aprender los índices de estabilidad de las unidades que se conectan a 400 kV.

El número de casos estables e inestables de entrenamiento y de prueba, se reportan en las tablas 5.2 y 5.3 respectivamente. Se observa que el número de resultados inestables es, por lo general, menor al número de casos estables. Empleando el criterio empírico de que el número de patrones por clase debería ser al menos diez veces el número de elementos de entrada, se pueden prever problemas en el entrenamiento de las redes correspondientes a los subespacios 1, 2, 3, 5, 6, 7, 9 y 10 de las unidades conectadas tanto a 230 como a 400 kV, y en la red del subespacio 13 para las unidades

conectadas en 230 kV.

Tabla 5.2

Número de Casos Estables e Inestables de Entrenamiento por Subespacio

Subespacio Núm.	Para unidades en 230 kV		Para unidades en 400 kV	
	Estables	Inestables	Estables	Inestables
1	392	40	387	45
2	359	73	359	73
3	342	90	342	90
4	306	126	329	103
5	361	71	354	78
6	342	90	339	93
7	331	101	329	103
8	286	146	308	124
9	344	88	339	93
10	331	101	329	103
11	312	120	310	122
12	252	180	270	162
13	329	103	311	121
14	307	125	291	141
15	273	159	256	176
16	205	227	205	227

En las tablas 5.4 y 5.5 se muestra el porcentaje de error obtenido al final del proceso de entrenamiento para RNA's con uno a diez elementos en la capa interna. Se utiliza el algoritmo de retropropagación de error para cada RNA y se emplean las doce variables de entrada listadas en la sección 4.3.1. La variable de salida consiste del índice de estabilidad binario, descrito en la misma sección.

Tabla 5.3

Número de Casos Estables e Inestables de Prueba por Subespacio

Subespacio Núm.	Para unidades en 230 kV		Para unidades en 400 kV	
	Estables	Inestables	Estables	Inestables
7	40	14	39	15
8	33	21	36	18
10	39	15	38	16
11	180	90	175	95
12	58	50	57	51
14	35	19	32	22
15	59	49	55	53
16	20	34	20	34

El mínimo error de entrenamiento correspondiente a RNA's asociadas a unidades conectadas a 230 kV, de la Tabla 5.4, es de 4.11%, para la RNA con dos elementos en la capa interna, entrenada con los patrones correspondientes al subespacio 1, mientras que el mayor error de entrenamiento es de 19.97%, para la RNA con 4 elementos en la capa interna y para los patrones del subespacio 16.

En la Tabla 5.5 se listan los errores de entrenamiento para redes asociadas a unidades conectadas a 400 kV. El mínimo error es de 4.68% y se presenta para la RNA con dos elementos en la capa interna, para el subespacio 1; el máximo error es de 18.61% y ocurre para la RNA con un elemento en la capa interna, y el subespacio 16.

En general no se obtienen valores aceptables de error. En todos los casos se realizan 500 iteraciones del proceso de entrenamiento con el algoritmo de retro-propagación del error, observándose que en la mayoría de los casos se alcanzan estos niveles de error desde antes de la iteración 200, sin mostrar tendencia a disminuir.

Tabla 5.4

Errores de Entrenamiento en Redes para Generadores Conectados a 230 kV[%]

RED	Numero de Elementos en la Capa Interna									
	1	2	3	4	5	6	7	8	9	10
1	4.46	4.11	4.26	4.36	4.50	4.64	4.45	4.64	4.49	4.13
2	6.50	6.78	6.93	6.90	6.88	6.95	6.61	7.04	6.61	6.58
3	7.87	7.63	7.39	7.69	7.46	7.59	7.43	7.40	7.39	7.58
4	11.00	11.01	10.63	10.77	11.36	10.50	10.70	11.24	10.49	10.86
5	6.25	6.28	6.51	6.72	6.24	6.74	6.50	6.29	6.23	6.25
6	7.97	7.40	7.39	7.59	7.70	7.44	7.43	7.38	7.42	7.40
7	8.35	8.59	8.43	8.37	8.38	8.39	8.42	8.39	8.40	8.51
8	12.74	13.56	12.28	12.26	12.27	12.80	12.52	12.41	13.31	12.87
9	7.47	7.32	7.31	7.33	7.32	7.51	7.34	7.36	7.39	7.56
10	9.05	8.64	8.74	8.62	8.64	8.91	9.08	8.89	8.60	8.82
11	12.21	12.74	11.57	11.58	11.41	11.82	11.80	11.86	12.08	12.73
12	17.40	15.57	15.39	15.09	15.47	15.19	16.30	15.19	15.02	15.28
13	10.07	9.48	9.80	9.55	9.67	10.18	9.37	9.51	10.06	9.65
14	13.22	12.76	13.09	13.22	12.64	12.48	12.24	12.70	12.78	12.20
15	15.90	15.97	16.37	16.05	16.68	16.62	16.72	15.57	16.90	15.73
16	18.73	19.92	17.96	19.97	17.80	18.86	17.93	18.38	18.24	17.85

El hecho de que no se obtengan niveles de error aceptables (menores a 1%), aún en los casos en que se tiene un buen balance de casos estables/inestables, indica que es más recomendable proporcionar la información agrupada por tipo de falla y voltaje, como se realizó en el capítulo IV, con lo que no se mezclan los resultados correspondientes a los diferentes tipos de fallas, sino que se mantienen independientes.

Con respecto a los resultados de los casos de prueba, reportados en las Tablas 5.6 y 5.7, se observa un error mínimo global de 10.24% y un máximo global de 21.79%.

Tabla 5.5

Errores de Entrenamiento en Redes para Generadores Conectados a 400 kV[%]

RED	Numero de Elementos en la Capa Interna									
	1	2	3	4	5	6	7	8	9	10
1	4.72	4.68	4.79	4.71	4.68	4.71	5.35	4.71	4.75	4.69
2	6.45	7.06	6.62	7.15	6.75	6.51	6.68	6.88	6.54	6.46
3	7.60	7.69	7.83	7.83	7.76	7.39	7.53	7.39	7.47	7.61
4	9.65	9.63	9.12	9.29	9.48	9.87	9.12	9.08	9.39	9.55
5	7.24	7.18	6.91	7.19	7.16	6.79	7.17	6.79	7.14	6.96
6	7.56	7.94	7.54	7.85	7.59	7.59	8.01	7.73	7.60	7.59
7	8.93	8.76	9.26	8.78	9.09	8.75	8.76	9.09	8.83	8.75
8	12.72	12.20	11.83	11.93	11.79	12.37	12.21	11.77	12.46	12.50
9	7.63	7.59	7.89	7.66	7.58	7.65	7.93	7.62	7.61	7.96
10	8.86	9.25	8.96	9.14	8.90	8.77	8.76	8.78	8.96	8.75
11	12.04	11.57	11.42	12.01	12.18	11.89	11.54	12.08	11.83	11.60
12	15.77	15.24	15.86	15.78	15.75	14.95	15.27	15.00	15.14	14.98
13	9.19	9.40	8.81	8.97	9.07	9.30	9.45	9.17	8.88	8.87
14	12.69	12.39	11.23	11.14	11.11	11.86	11.51	11.14	11.26	11.95
15	15.98	14.44	15.04	14.59	14.11	14.48	14.76	14.07	14.07	14.05
16	18.61	17.27	17.37	18.47	16.91	18.09	17.47	16.65	17.66	16.65

Los errores de entrenamiento de las Tablas 5.4 y 5.5 se pueden comparar con los valores obtenidos en la Tabla 4.4, donde los patrones de entrenamiento se agruparon por tipo de falla y voltaje, y donde el máximo error obtenido fué de 1.85%.

A su vez, los errores de prueba de las Tablas 5.6 y 5.7 son mayores a los que se muestran en la Tabla 4.5, donde el máximo fué de 6.89%.

Tabla 5.6

Errores de Prueba en Redes para Generadores Conectados a 230 kV[%]

RED	Numero de Elementos en la Capa Interna									
	1	2	3	4	5	6	7	8	9	10
7	10.62	10.97	10.48	10.32	10.37	10.24	10.75	10.59	10.59	10.64
8	15.73	16.49	15.18	15.36	16.51	16.85	15.72	16.52	16.65	16.26
10	13.04	11.87	12.22	11.87	12.17	12.35	12.24	12.07	11.94	11.99
11	16.86	15.65	14.53	15.08	14.60	14.94	15.70	15.36	15.22	17.17
12	19.97	18.26	17.77	17.79	18.65	18.40	19.29	18.12	18.26	18.80
14	16.36	17.19	17.89	16.40	16.32	16.47	15.75	16.13	17.49	15.96
15	19.48	19.28	20.44	19.33	21.05	20.40	20.28	19.38	21.79	19.77
16	19.16	20.46	18.15	20.30	18.42	18.96	18.42	18.69	18.16	18.29

Tabla 5.7

Errores de Prueba en Redes para Generadores Conectados a 400 kV[%]

RED	Numero de Elementos en la Capa Interna									
	1	2	3	4	5	6	7	8	9	10
7	12.48	12.02	12.65	11.95	12.36	11.98	12.13	12.44	12.27	12.18
8	17.15	15.35	15.16	15.27	15.61	16.45	15.42	15.33	16.63	16.08
10	13.59	13.67	13.32	13.60	13.27	13.51	13.45	13.57	13.79	13.39
11	15.86	15.34	15.47	16.16	16.13	16.17	15.82	16.71	16.09	15.52
12	19.29	18.88	20.28	19.28	19.79	18.41	19.29	18.48	19.18	18.98
14	20.44	17.08	17.20	15.83	17.20	18.52	17.02	16.59	16.62	16.45
15	20.29	19.13	20.71	19.70	18.84	19.84	19.65	19.08	18.95	19.03
16	19.29	18.86	19.59	19.97	19.84	19.60	19.59	18.86	20.63	18.83

5.2.1 Análisis de Errores

En el proceso de entrenamiento de los patrones de estabilidad descrito en el Capítulo IV se observó una relación general entre el número de patrones por clase (estable o inestable), y la suma cuadrática del error de entrenamiento. Mientras menor es la relación numérica de casos inestables a estables (RCIE), menores valores de error se alcanzaron. Sin embargo, es deseable tener valores de RCIE cercanos a 1 para lograr un equilibrio en el número de patrones por clase.

En la Tabla 4.4 se observa que las redes 2 y 8, con valores de RCIE cercanos a 1, logran alcanzar errores de entrenamiento menores a 1%. Estas redes se especializan en clasificar la estabilidad de los generadores de la planta al ocurrir una falla, considerando diferentes condiciones operativas que incluyen cambios en topología, demanda y niveles de generación.

Al agrupar los patrones de entrenamiento por espacio de generación, los errores de entrenamiento no resultan menores al 4% (Red 1, Tabla 5.4). En este caso el valor de RCIE es de 0.1. Para las redes del sub-espacio de generación 16, con un valor de RCIE de 1.1, se obtienen valores de error mayores al 17%. El proceso de entrenamiento trata de producir redes especializadas en clasificar la estabilidad en un cierto subespacio de generación, considerando varias contingencias y variaciones en la demanda y en la topología.

Se concluye que es muy importante la forma de distribución de la información de los patrones de entrada, para lograr reducir los errores de clasificación. Se observa además que el comportamiento dinámico del sistema de potencia obedece ciertos patrones y que éstos son más fáciles de predecir cuando se considera una sola falla en diferentes condiciones operativas, que cuando se consideran varias fallas, aún cuando la condición operativa de generación no cambie.

5.3 Una Red por cada Tipo de Falla y Voltaje

La organización de los patrones de entrenamiento por tipo de falla y por voltaje se empleó en el capítulo IV para el entrenamiento de RNA's donde se utilizó un índice de estabilidad binario (0,1) como la variable de salida. En esta sección se investiga la utilización de otras variables de salida, que pueden tomar múltiples valores: La potencia activa generada por las unidades y el defasamiento angular de los rotores al final del período de estudio.

5.3.1 Potencia Generada Final como Variable de Salida

De cada estudio de estabilidad transitoria se obtuvo el valor de la potencia generada por las unidades conectadas en 230 kV y en 400 kV, al término del tiempo de estudio (1 segundo de simulación), para analizar su utilidad como variable de salida, aplicada al problema de análisis de seguridad dinámica. Las señales de entrada son las 12 variables descritas en la sección 4.3.1.

Los valores de potencia generada final se agruparon en 12 vectores de 448 elementos, se escalaron y normalizaron al intervalo (0,1). Se tienen por lo tanto 12 RNA's, una para cada tipo de falla y nivel de voltaje al que se conectan las unidades de la planta.

Separando los valores de potencia para los casos estables e inestables de acuerdo al índice de estabilidad, se puede mostrar el espectro de valores que se obtienen para cada uno de los casos. Las Figuras 5.2 a 5.7 muestran los valores de P_g final, normalizados, para las unidades conectadas a 230 kV. Las Figuras 5.8 a 5.13 muestran los valores que corresponden a las unidades conectadas a 400 kV. En general, el número de resultados estables e inestables es diferente para cada caso, (Ver Tabla 4.2), predominando la clase de resultados estables.

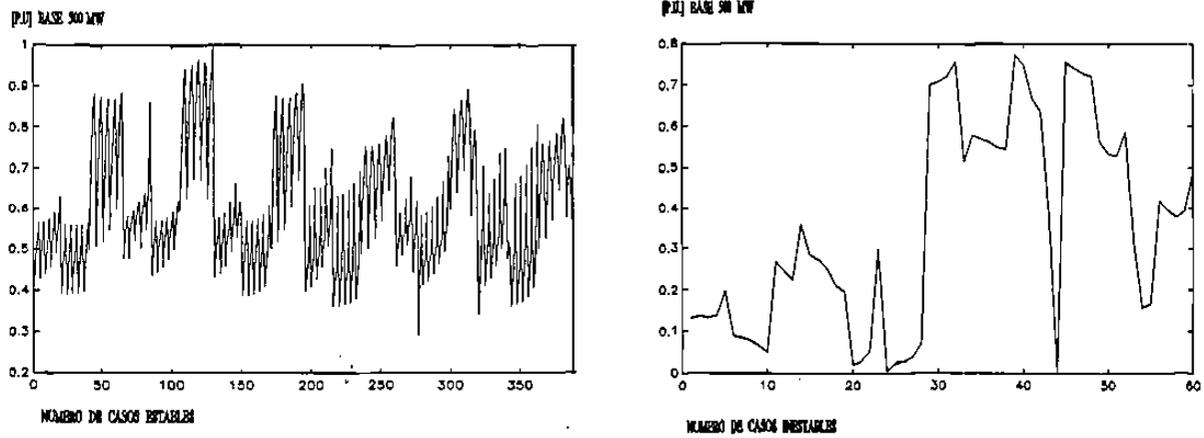


Fig. 5.2 Valores normalizados de Pg. Caso 1.

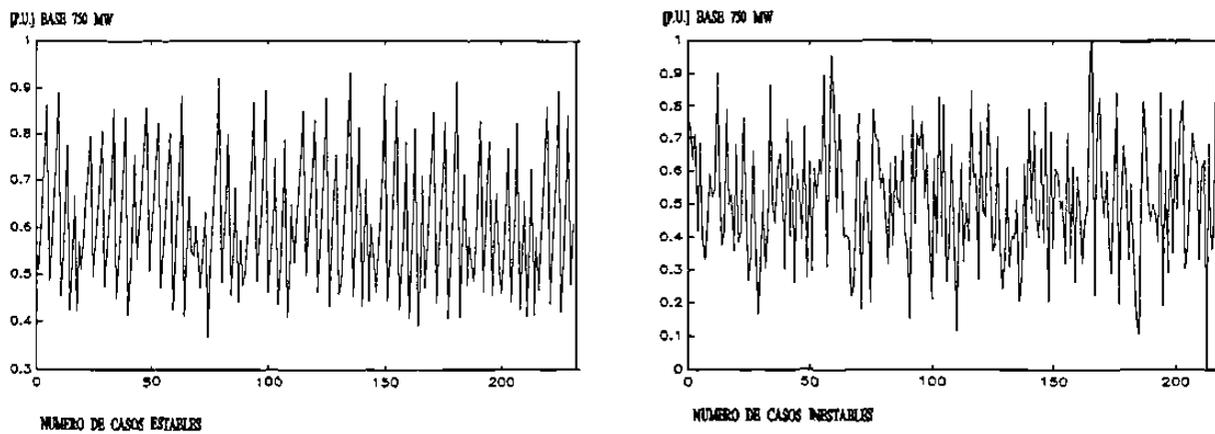


Fig. 5.3 Valores normalizados de Pg. Caso 2.

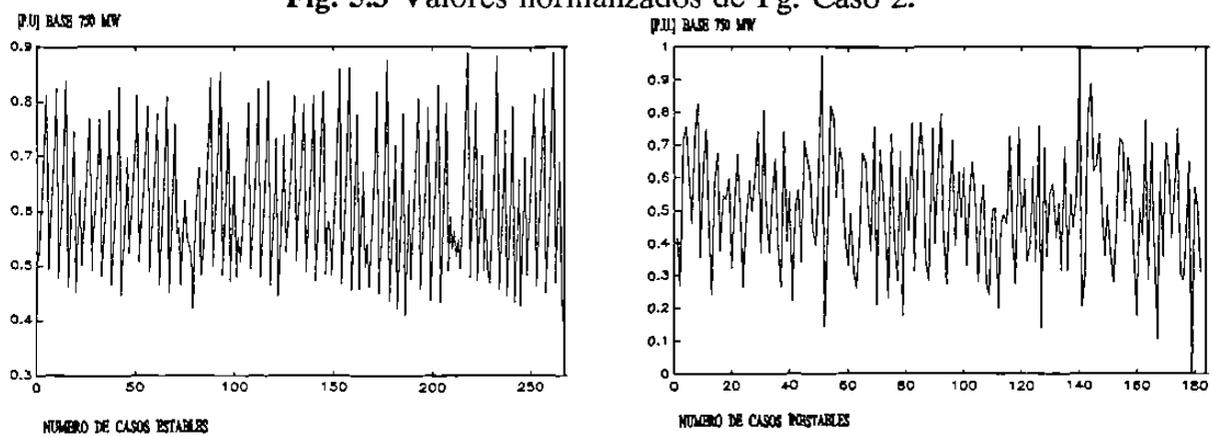


Fig. 5.4 Valores normalizados de Pg. Caso 3.

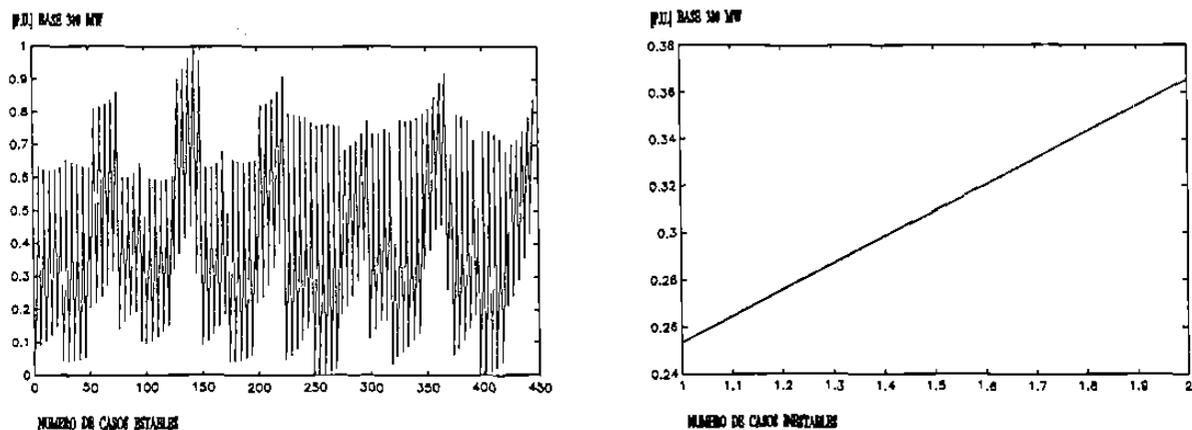


Fig. 5.5 Valores normalizados de Pg. Caso 4.

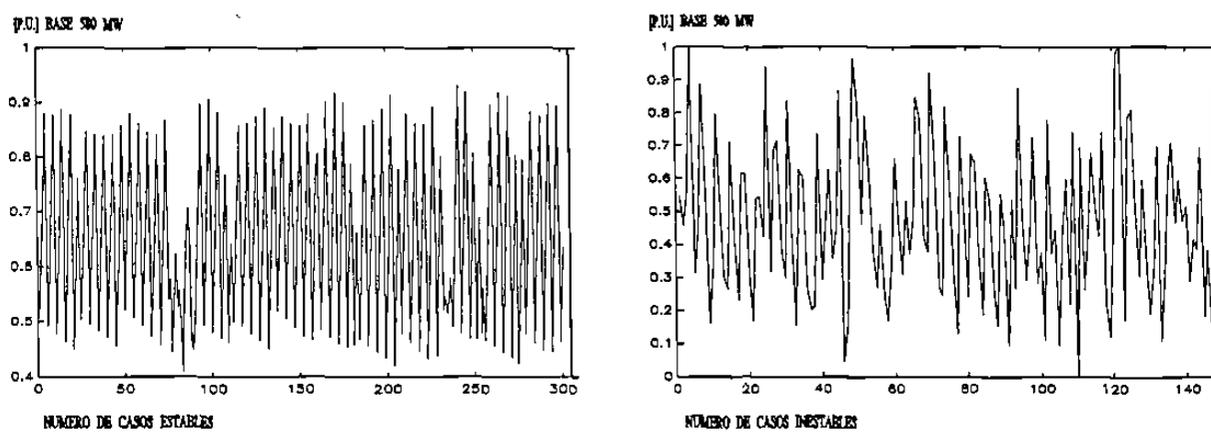


Fig. 5.6 Valores normalizados de Pg. Caso 5.

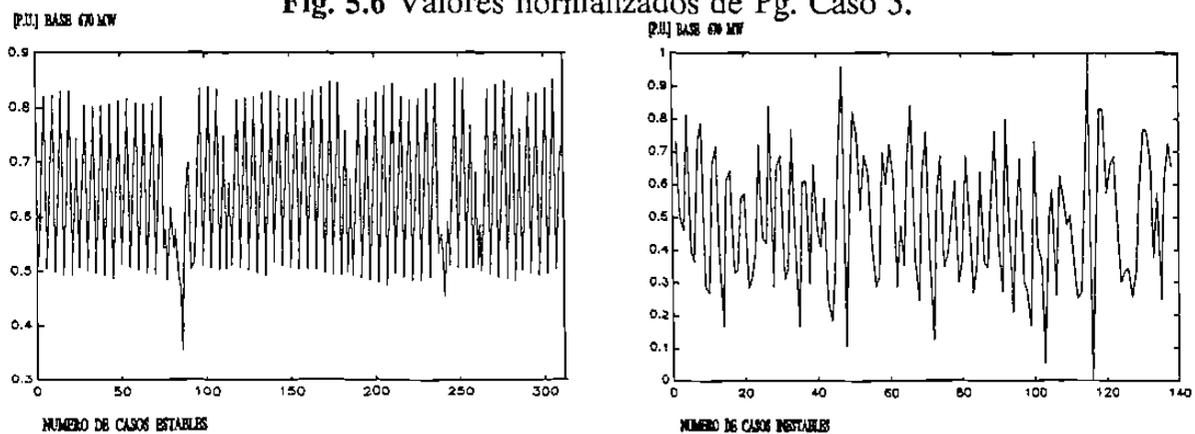


Fig. 5.7 Valores normalizados de Pg. Caso 6.

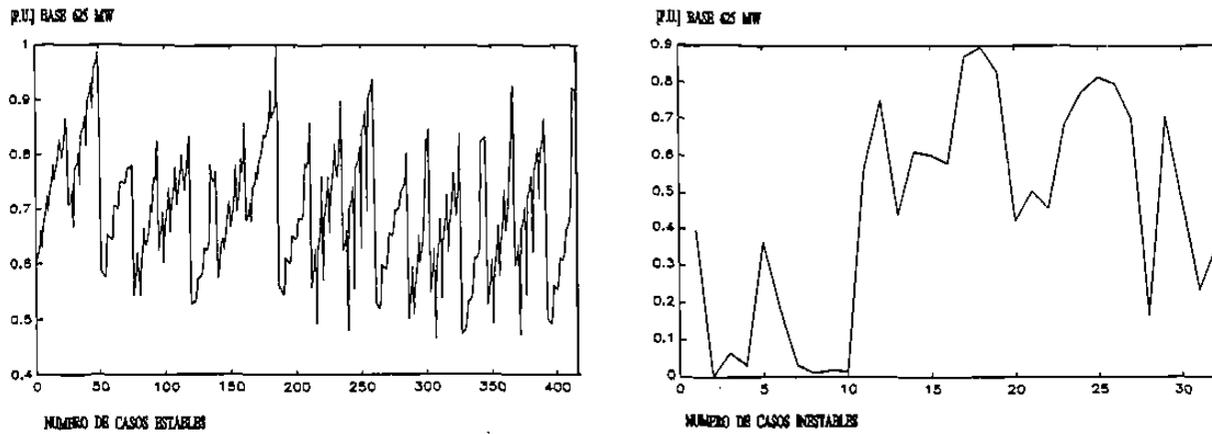


Fig. 5.8 Valores normalizados de Pg. Caso 7.

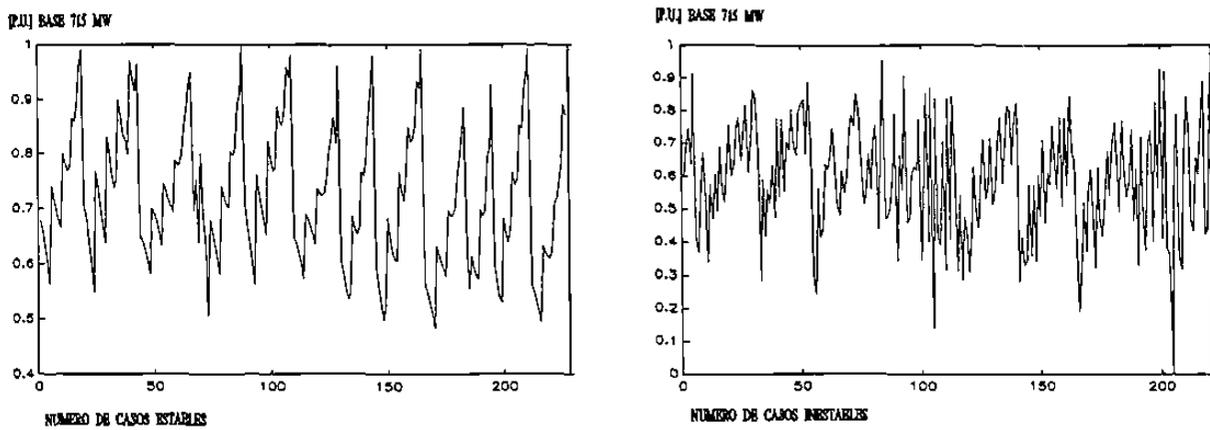


Fig. 5.9 Valores normalizados de Pg. Caso 8.

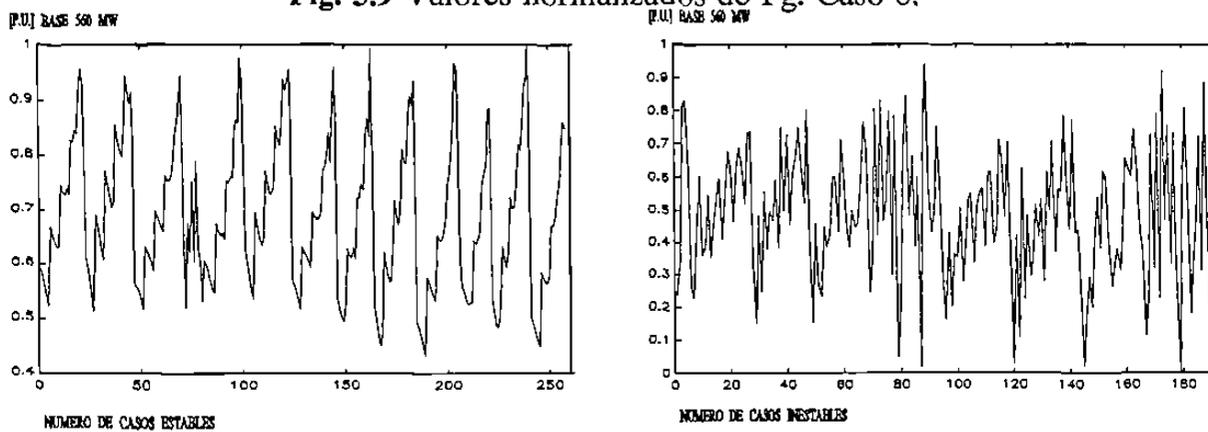


Fig. 5.10 Valores normalizados de Pg. Caso 9.

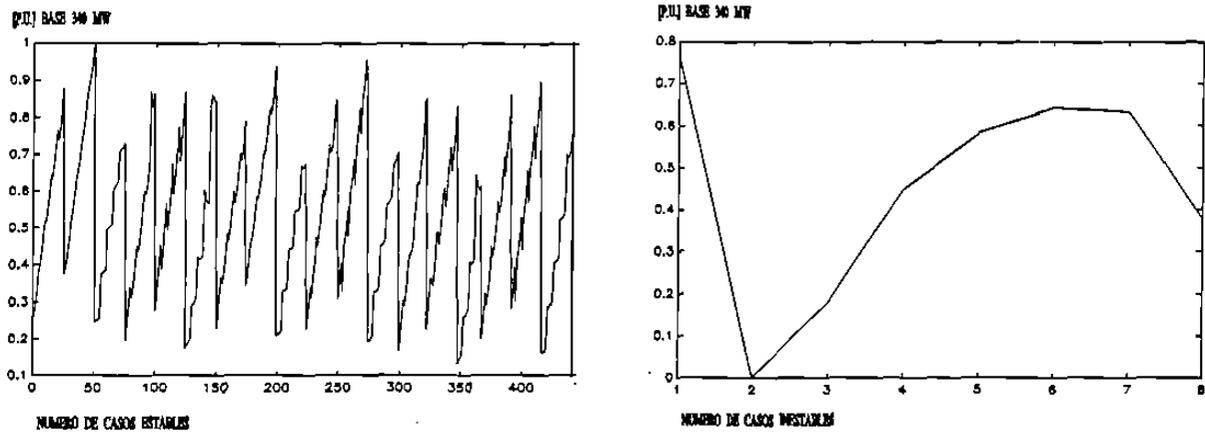


Fig. 5.11 Valores normalizados de Pg. Caso 10.

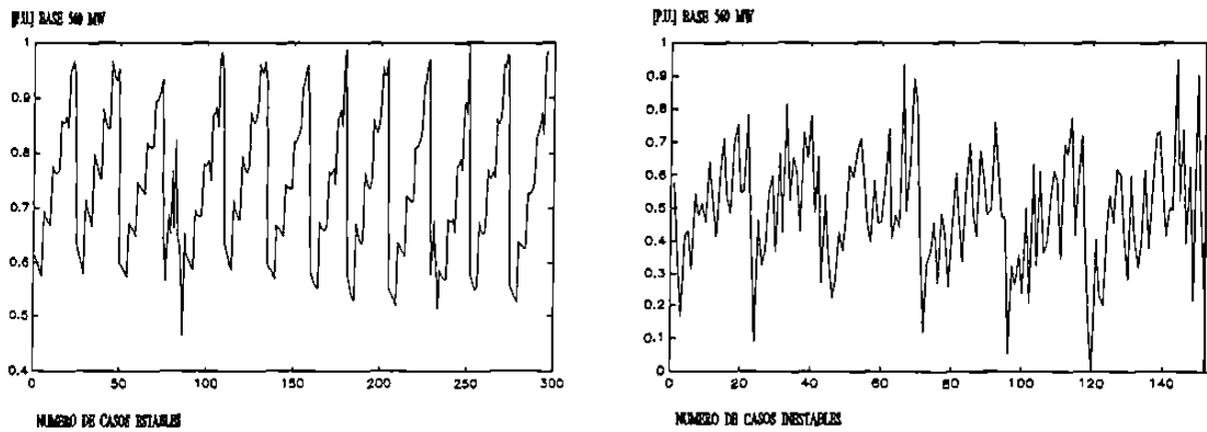


Fig. 5.12 Valores normalizados de Pg. Caso 11.

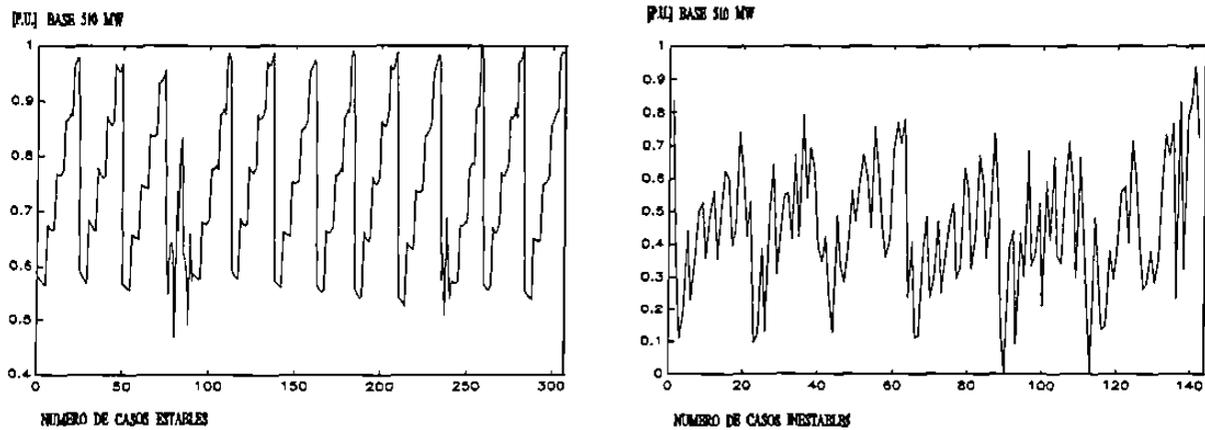


Fig. 5.13 Valores normalizados de Pg. Caso 12.

Tabla 5.8
Errores de Entrenamiento en Redes

RED	Numero de Elementos en la Capa Interna									
	1	2	3	4	5	6	7	8	9	10
1	1.82	1.58	1.35	1.28	1.01	1.59	1.27	0.74 *	0.97	1.00
2	1.69	1.62	1.71	1.63	1.59	1.63	1.63	1.74	1.56 *	1.64
3	1.63	1.44	1.50	1.44	1.50	1.50	1.51	1.44	1.50	1.43 *
4	0.45	0.34	0.33	0.32	0.33	0.32	0.30	0.28 *	0.34	0.30
5	1.72	1.70	1.72	1.51 *	1.65	1.70	1.59	1.89	1.78	1.70
6	1.14	1.16	1.19	1.15	1.14	1.14	1.12	1.11	1.11	1.09 *
7	1.32	1.19	1.18	1.11	1.03	1.16	1.08	0.92 *	0.98	0.94
8	1.44	1.25	1.44	1.19	1.31	1.18 *	1.30	1.22	1.39	1.30
9	2.17	1.43	1.62	1.41 *	1.44	1.51	1.45	1.86	1.56	1.54
10	0.42	0.40	0.36	0.41	0.38	0.38	0.34 *	0.36	0.38	0.43
11	1.18	0.88	0.74 *	0.89	0.82	0.97	0.84	0.77	0.79	0.81
12	1.14	0.90	0.73 *	0.78	0.77	0.87	0.78	0.76	0.85	0.88

El rango en el que se encuentran los errores de entrenamiento para las redes seleccionadas va desde 0.28% a 1.56%

Los porcentajes de error de prueba obtenidos para cada una de las RNA's se muestran en la Tabla 5.9. Con (*) se marcan las posiciones donde en la Tabla 5.9 se localizaron las redes con error de entrenamiento mínimo. En este caso el rango de valores del error de prueba va desde 0.18% a 3.06%.

Aún cuando parecen obtenerse porcentajes de error de entrenamiento y de prueba reducidos, no se logran predicciones aproximadas de los valores de la variable de salida. Fijando una tolerancia de $\pm 5\%$ con respecto al valor base de normalización de cada caso, se contabilizaron los casos de entrenamiento y de prueba que no cumplen con esta tolerancia, para las 12 RNA's que lograron los mínimos errores de

entrenamiento.

Los resultados de este análisis se muestran en la Tabla 5.10, donde se lista el número de patrones de entrenamiento y de prueba con error superior al $\pm 5\%$, el porcentaje real de error con esta tolerancia y las magnitudes de potencia generada base de cada caso.

El porcentaje real de error de entrenamiento se extiende desde un mínimo de 18.1% hasta un máximo de 58.7%, mientras que el de prueba se encuentra entre 22.7% y 88.6% respectivamente.

Tabla 5.9
Errores de Prueba en Redes

RED	Numero de Elementos en la Capa Interna									
	1	2	3	4	5	6	7	8	9	10
1	2.28	3.17	5.45	4.49	4.23	2.79	4.27	2.82 *	3.66	2.92
2	1.86	1.83	2.04	1.91	1.85	1.85	1.92	1.97	1.84 *	2.06
3	1.60	1.53	1.57	1.63	1.62	1.69	1.54	1.62	1.69	1.66 *
4	0.30	0.33	0.15	0.38	0.52	0.23	0.24	0.31 *	0.28	0.24
5	2.01	2.04	2.10	1.72 *	1.71	1.97	1.89	2.31	2.11	1.95
6	1.20	1.08	1.29	1.23	1.31	1.05	1.00	1.17	1.19	1.12 *
7	1.81	1.97	1.70	2.28	2.22	1.83	1.92	3.06 *	1.92	2.03
8	1.93	1.62	1.80	1.51	1.67	1.48 *	1.62	1.48	1.65	1.58
9	3.31	1.27	1.66	1.57 *	1.39	1.55	1.43	2.07	1.68	1.66
10	0.10	0.13	0.22	0.09	0.11	0.14	0.18 *	0.15	0.22	0.33
11	1.52	1.11	1.00 *	1.37	1.13	1.06	1.00	1.17	0.96	1.09
12	0.98	0.75	0.69 *	0.89	0.80	0.75	0.88	0.83	1.00	1.00

Tabla 5.10
Patrones con error superior al $\pm 5\%$

RED	DE ENTRENAMIENTO		DE PRUEBA		Pg _{BASE} [MW]
	NUM.	% ERROR	NUM.	% ERROR	
1	204	45.5	58	65.9	500
2	263	58.7	78	88.6	750
3	248	55.3	74	84.1	750
4	132	29.5	35	39.8	310
5	194	43.3	61	69.3	580
6	168	37.5	42	47.7	670
7	154	34.4	61	69.3	625
8	226	50.4	71	80.7	715
9	218	48.7	67	76.1	560
10	81	18.1	20	22.7	340
11	161	35.9	54	61.4	560
12	160	35.7	37	42.0	510

Estos niveles de desempeño descalifican la aplicación de la metodología de redes de neuronas artificiales, cuando se utiliza la potencia generada final como variable de salida.

5.3.2 Índice de Estabilidad basado en Potencia generada

En la sección anterior se mostró que no se obtienen buenos resultados al utilizar un valor puntual, en el tiempo, de la potencia generada para clasificar casos estables e inestables. Sin embargo, es posible diseñar un índice de estabilidad binario, que se base en el comportamiento en el tiempo de la potencia generada.

De cada estudio de estabilidad en el tiempo se obtienen las áreas de aceleración y desaceleración, de acuerdo al criterio de áreas iguales. No es posible en este caso una aplicación estricta de este criterio, sin embargo, el análisis de una gran cantidad de casos mostró que la inestabilidad de la planta se asegura cuando existe al menos una relación 2:1 entre area de aceleración y area de desaceleración; en este caso se asigna el valor 1 al índice de estabilidad binario. Cuando la relación entre areas es menor a 2, se asigna el valor cero al índice de estabilidad.

De esa manera se generan doce nuevos patrones de salida, seis corresponden al comportamiento de las unidades conectadas a 230 kV y otros seis a las unidades en 400 kV. Cada uno de los patrones se representa por un vector de 448 elementos.

La Tabla 5.11 muestra el número de casos estables e inestables para cada una de las 12 RNA's, tanto de entrenamiento como de prueba. De acuerdo a lo esperado, se observa una gran similitud con el número de casos estables e inestables reportados en la Tabla 4.2, donde se utilizó un índice de estabilidad basado en el ángulo.

En la Tabla 4.2 se reportan un total de 1491 casos de entrenamiento inestables, contra un total de 1598 en la Tabla 5.11. De aquí se concluye que el índice basado en potencia generada es más estricto en la estimación de la estabilidad de la planta.

Además en este caso no se consideró el establecimiento de las categorías de casos críticos, (críticamente estables o inestables), pero esto se podría realizar de manera simple estableciendo los correspondientes rangos de valores para la relación entre areas de aceleración y desaceleración.

Considerando un mínimo de 120 casos inestables, para obtener buenos resultados en la etapa de entrenamiento, se prevén problemas de clasificación para las redes números 1, 4, 7 y 10, donde el número de casos inestables está por debajo del mínimo señalado por reconocimiento de patrones.

TABLA 5.11
Número de Casos por Categoría de Clasificación

RED NUM.	Casos de Entrenamiento		Casos de Prueba	
	Estables	Inestables	Estables	Inestables
1	388	60	77	11
2	226	222	16	72
3	246	202	22	66
4	445	3	88	0
5	279	169	44	44
6	270	178	40	48
7	410	38	72	16
8	247	201	14	74
9	250	198	18	70
10	436	12	86	2
11	294	154	39	49
12	287	161	38	50
Total	3778	1598	554	502

Los patrones de entrada son los que se describen en la sección 4.3.1 y que se componen de los valores de 12 variables de estado estable.

Se utiliza la arquitectura A, descrita en la sección 4.5, el algoritmo de retropropagación de error y se fija un máximo de 500 iteraciones o un error de entrenamiento menor al 0.2%, como meta. Se realizan pruebas con RNA's de uno a diez elementos en la capa interna.

En la Tabla 5.12 se muestran los valores de la suma cuadrática de error, obtenidos al final del proceso de entrenamiento para cada una de las RNA's.

Si se utilizaran RNA's con el mismo número de elementos en la capa oculta, se sugeriría el empleo de redes con 5 elementos, pues de acuerdo a los valores del último renglón de la Tabla 5.12, son las que logran el menor error promedio en la etapa de entrenamiento.

La red número 4 logra obtener los menores errores de entrenamiento, sin embargo se debe recordar que en este caso y para las redes 1, 7 y 10 se observó una mala distribución de los casos estables/inestables. El valor mayor de error (1.59%), se tiene para la red 3, con cuatro elementos en la capa interna.

TABLA 5.12
Suma Cuadrática de Errores de Entrenamiento [%]

RED Num.	Número de Neuronas en la Capa Interna									
	1	2	3	4	5	6	7	8	9	10
1	0.27	0.29	0.29	0.39	0.21	0.27	0.33	0.20	0.22	0.22
2	0.89	1.09	1.18	0.90	1.06	1.09	1.45	1.05	1.33	0.94
3	0.95	0.91	1.36	1.59	1.24	1.27	1.25	1.22	1.10	1.23
4	0.08	0.07	0.14	0.12	0.12	0.11	0.09	0.06	0.07	0.10
5	0.94	0.99	0.98	0.95	0.74	0.89	1.09	0.93	0.99	0.78
6	0.65	0.61	0.50	0.64	0.57	0.50	0.63	0.63	0.54	0.60
7	0.60	0.51	0.43	0.60	0.36	0.61	0.59	0.43	0.75	0.67
8	1.23	1.03	1.25	1.11	1.02	1.46	1.26	0.94	0.70	1.06
9	1.31	0.72	1.00	0.76	0.95	1.27	0.87	1.29	1.00	0.91
10	0.59	0.38	0.40	0.44	0.42	0.60	0.56	0.31	0.57	0.29
11	1.07	1.18	1.11	0.97	0.99	1.19	0.88	1.12	1.28	1.10
12	1.10	1.20	1.24	1.09	1.10	1.20	1.27	1.15	1.29	1.22
PROM.	0.81	0.75	0.82	0.80	0.73	0.87	0.86	0.78	0.82	0.76

La Tabla 5.13 contiene los valores de la suma cuadrática de error, para la etapa de prueba. Se observa que el mínimo error promedio corresponde también a las redes con 5 elementos en la capa interna.

El máximo error de prueba (6.81%), se tiene en la red número 6, con tres elementos en la capa interna.

TABLA 5.13
Suma Cuadrática de Errores de Prueba [%]

RED Num.	Número de Neuronas en la Capa Interna									
	1	2	3	4	5	6	7	8	9	10
1	5.03	4.83	5.69	5.39	5.00	5.88	5.33	5.46	5.01	4.97
2	4.60	4.62	4.76	5.24	4.68	5.08	5.17	4.75	4.91	5.20
3	3.68	3.53	3.71	3.96	3.66	3.64	4.04	3.42	4.46	3.85
4	0.13	0.14	0.25	0.22	0.21	0.18	0.20	0.14	0.11	0.18
5	3.65	3.90	4.11	3.69	3.77	3.68	3.90	3.85	3.66	3.63
6	6.02	6.61	6.81	6.18	6.29	6.52	6.27	6.46	5.92	6.11
7	5.08	6.37	5.21	4.56	4.80	5.88	4.90	4.53	4.63	4.64
8	4.53	4.50	4.28	4.36	3.96	4.41	3.82	4.94	4.14	4.73
9	4.36	3.68	4.56	4.38	4.46	4.67	3.87	4.52	4.42	4.91
10	1.17	1.04	0.92	0.94	0.88	1.13	1.21	0.85	1.02	0.92
11	4.05	4.59	4.70	4.23	4.14	4.50	4.16	4.11	3.95	3.86
12	5.72	5.00	5.27	5.19	5.10	4.73	5.39	5.44	5.29	5.36
PROM.	4.00	4.07	4.19	4.03	3.91	4.19	4.02	4.04	3.96	4.03

En la Tabla 5.14 se muestra el número de patrones clasificados erróneamente por cada red, durante la etapa de entrenamiento. Se señalan con (*) aquellas redes que tienen el menor número de errores y que a la vez tienen el menor número de elementos en la capa interna.

El número total de clasificaciones incorrectas para este grupo de 12 RNA's es de 14 lo que equivale a un 0.26% de error global.

Si el desempeño óptimo se considera como aquel que produce un mínimo de errores en la etapa de prueba, el número de casos con error es de 24, esto es un 0.45% de error global. Estas redes se señalan con (**).

TABLA 5.14

Número de Clasificaciones Incorrectas en Etapa de Entrenamiento

RED Num.	Número de Neuronas en la Capa Interna									
	1	2	3	4	5	6	7	8	9	10
1	0*	0**	0	0	0	0	0	0	0	0
2	2*	3	4	2	2	3	6	2	6**	2
3	2**	1*	7	5	2	5	4	3	1	4
4	0*	0	0	0	0	0	0	0	0	0
5	3**	3	2*	3	2	3	3	3	3	3
6	2	2	1*	3	2	2	2	2**	3	3
7	1*	2	2	2	1	2	1	2	3	1
8	1	1	2	1**	1	3	0*	0	0	0
9	6	0*	3	0	2	4	0	5	2	3
10	4	1*	2	1	2	5	3	1	4	1
11	3**	4	4	3	4	4	2*	3	5	4
12	4*	4	5	3	5	4	6**	5	6	6
TOTAL	28	21	32	23	23	35	27	26	33	27

Los casos con mínimo número de errores de prueba se señalan en la Tabla 5.15 con (**). En total se tienen 56 patrones mal clasificados, lo que equivale a un 5.30% de error.

El grupo de redes para las que se obtuvo el menor número de errores de entrenamiento, durante la etapa de prueba logran un total de 65 clasificaciones incorrectas, esto es, un 6.16% de error.

Comparando estos niveles de desempeño con los obtenidos, cuando se utiliza solo el valor final de la potencia generada, se concluye que esta nueva opción es la mejor.

TABLA 5.15

Número de Clasificaciones Incorrectas en Etapa de Prueba

RED Num.	Número de Neuronas en la Capa Interna									
	1	2	3	4	5	6	7	8	9	10
1	8*	7**	9	8	8	9	9	8	7	7
2	7*	7	7	7	9	7	7	7	6**	8
3	3**	4*	5	5	3	6	6	3	6	5
4	0*	0	0	0	0	0	0	0	0	0
5	5**	6	6*	6	5	5	7	6	5	5
6	10	11	11*	9	10	9	10	8**	9	10
7	5*	7	6	5	5	8	5	5	5	5
8	6	6	6	5**	7	5	6*	7	6	7
9	7	5*	8	9	9	8	6	7	6	8
10	1	0*	0	0	0	4	4	0	0	0
11	6**	7	6	6	6	6	6*	6	6	6
12	7*	7	7	7	7	7	6**	6	7	7
TOTAL	65	67	71	67	69	71	69	63	63	68

5.3.3 Angulo Final como Variable de Salida

En esta sección se presenta un análisis de la utilización del valor del defasamiento angular relativo de los rotores de las unidades de la planta Rio Escondido, como variable de salida para un sistema de redes de neuronas artificiales.

El valor en radianes del ángulo, obtenido al final del tiempo de estudio, para cada uno de los casos de entrenamiento se agrupó en 12 vectores. Seis de ellos contienen la información correspondiente a las unidades conectadas a 230 kV, mientras que el resto agrupa la información de las unidades conectadas a 400 kV. Los datos se normalizaron y escalaron al intervalo (0,1). La escala encontrada para los casos de entrenamiento se utilizó para normalizar los datos de los casos de prueba.

Los espectros de valores que alcanza el ángulo, para las unidades conectadas a 230 kV, se muestran en las figuras 5.14 a 5.19. A las unidades conectadas en 400 kV, corresponden las figuras 5.20 a 5.25.

Al igual que cuando se emplea la potencia generada final como variable de salida, los valores por unidad de diferencias angulares se separaron, para cada caso, en dos grupos: Los que estan asociados a un índice de estabilidad estable, y los que se asocian con un índice de estabilidad inestable. De acuerdo con esto, se tienen cuatro casos, (1,4,7,10), para los que existe una gran diferencia cuantitativa entre el número de patrones estables e inestables, para los que no se esperan buenos resultados del proceso de entrenamiento. En cada una de las Figs. 5.14 a 5.25 se grafican separadamente los casos estables e inestables.

En todas las gráficas se observa que existe una separación entre las magnitudes por unidad, que alcanza el defasamiento angular, para los casos estables e inestables. Esta característica se aprovechó en el capítulo IV en el diseño del índice de estabilidad binario.

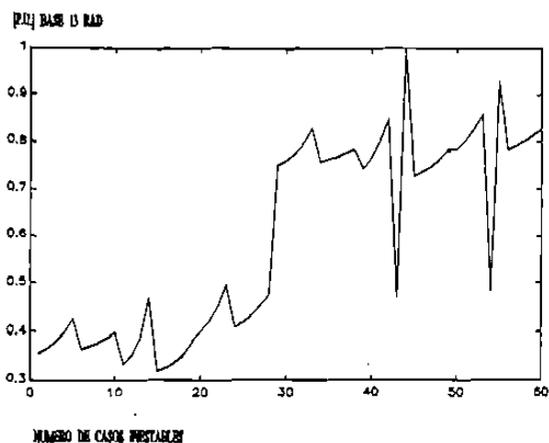
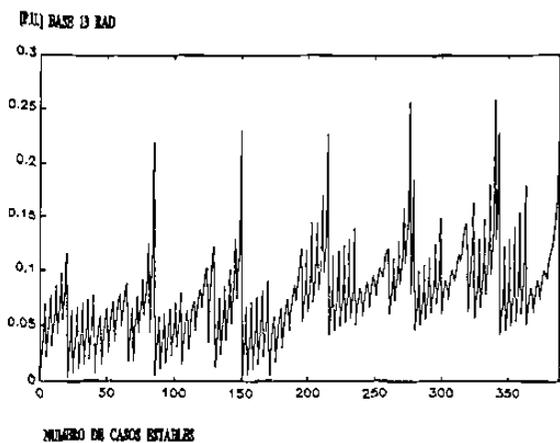


Fig. 5.14 Valores normalizados de diferencia angular. Caso 1.

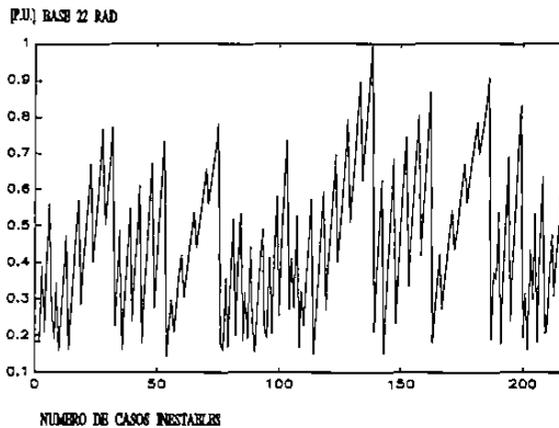
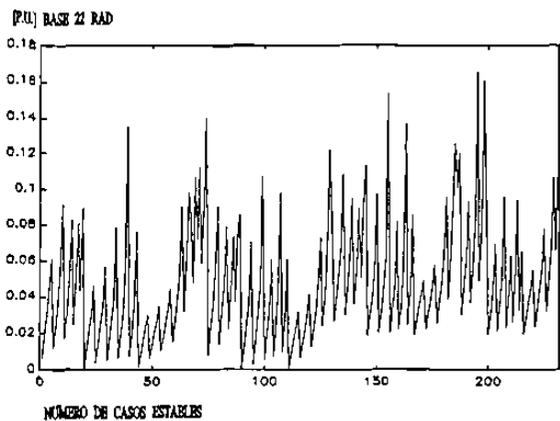


Fig. 5.15 Valores normalizados de diferencia angular. Caso 2.

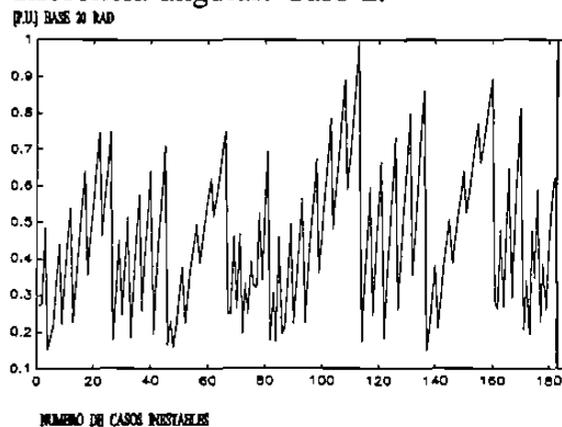
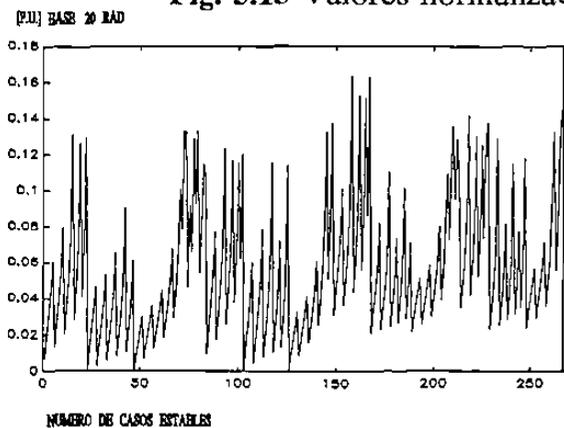


Fig. 5.16 Valores normalizados de diferencia angular. Caso 3.

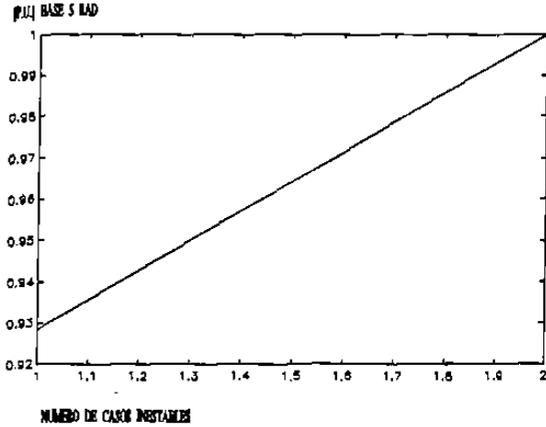
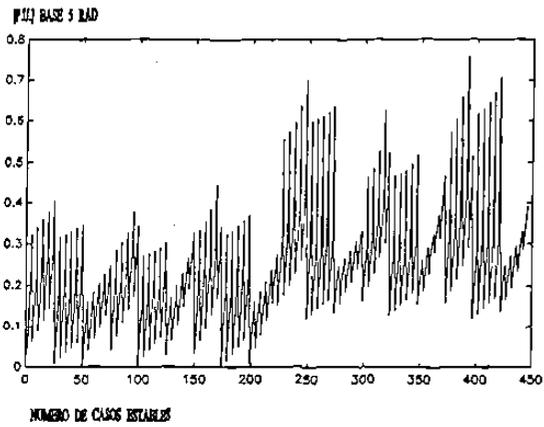


Fig. 5.17 Valores normalizados de diferencia angular. Caso 4.

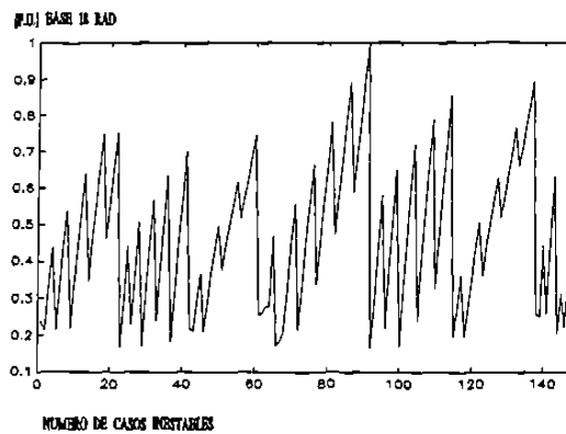
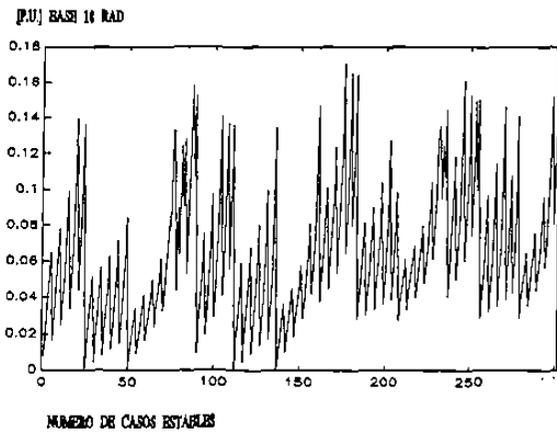


Fig. 5.18 Valores normalizados de diferencia angular. Caso 5.

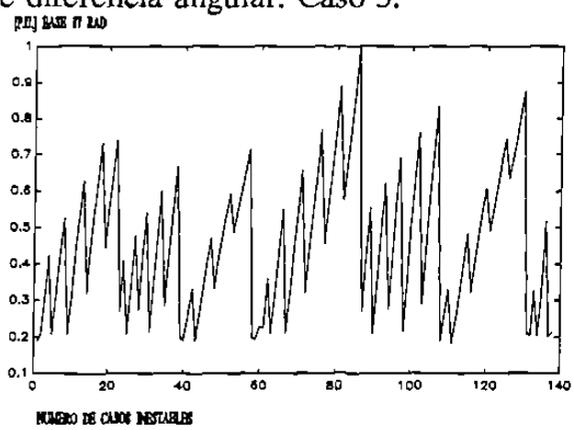
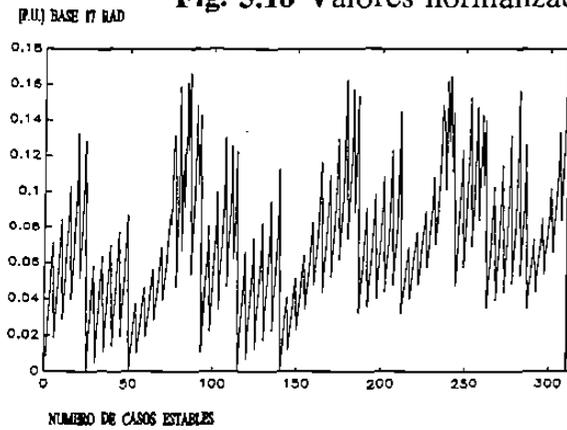


Fig. 5.19 Valores normalizados de diferencia angular. Caso 6.

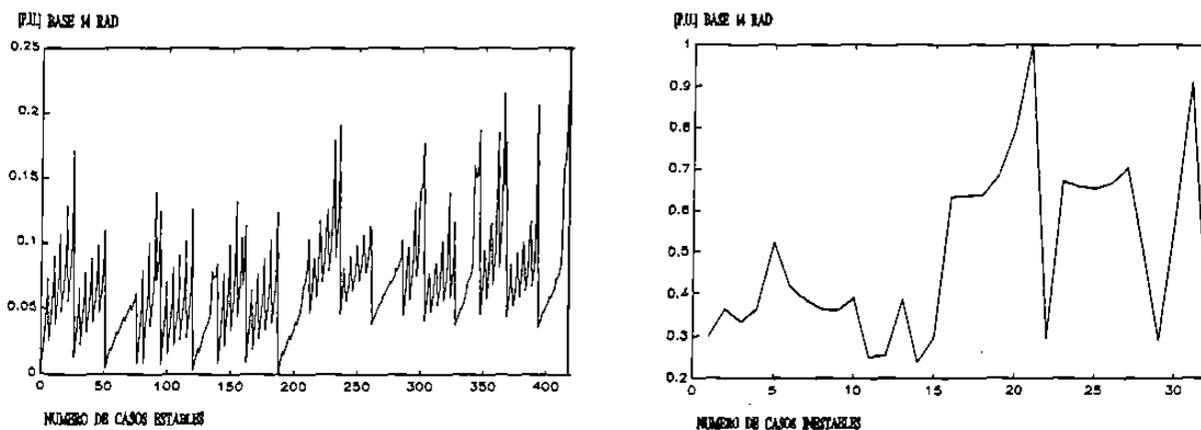


Fig. 5.20 Valores normalizados de diferencia angular. Caso 7.

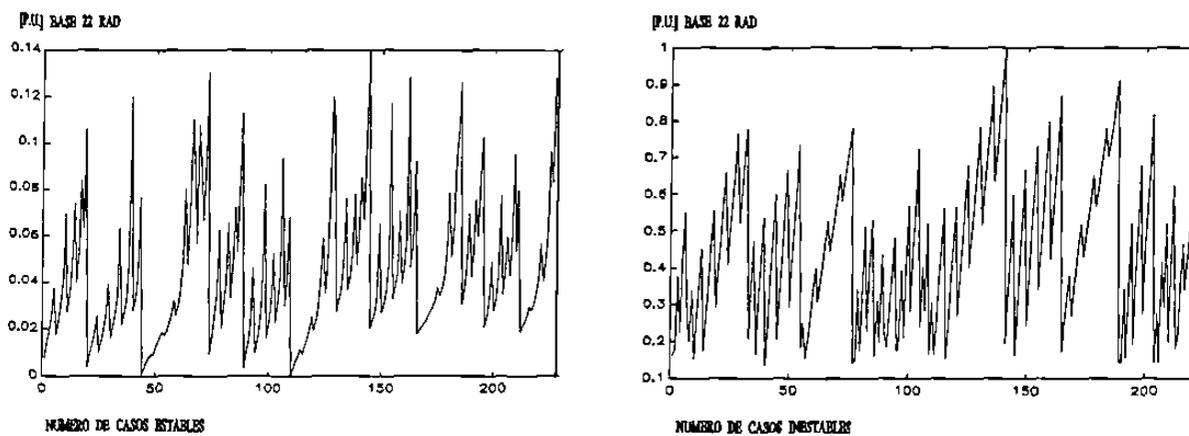


Fig. 5.21 Valores normalizados de diferencia angular. Caso 8.

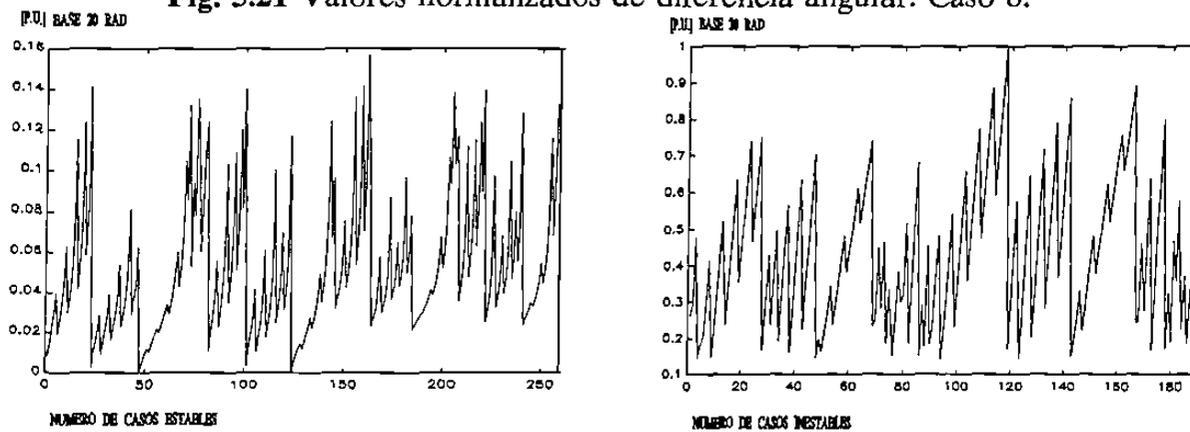


Fig. 5.22 Valores normalizados de diferencia angular. Caso 9.

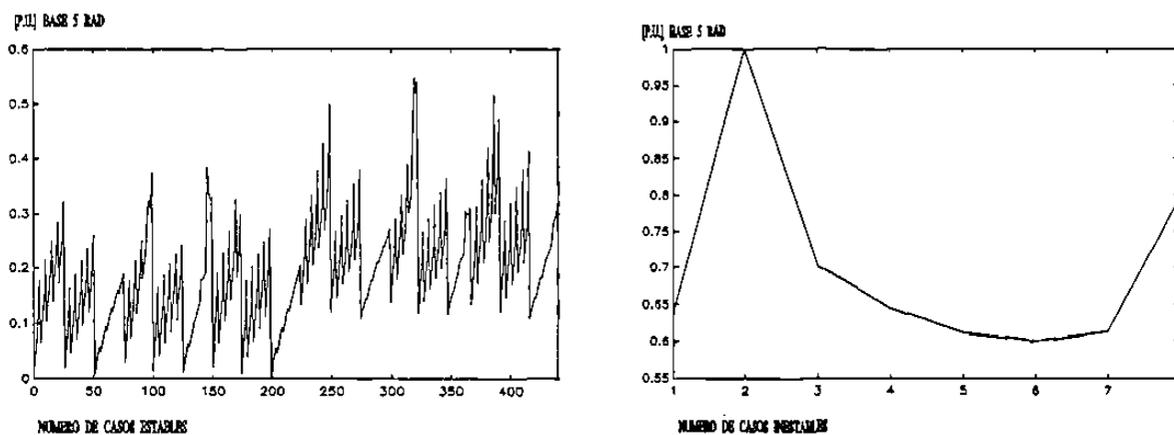


Fig. 5.23 Valores normalizados de diferencia angular. Caso 10.

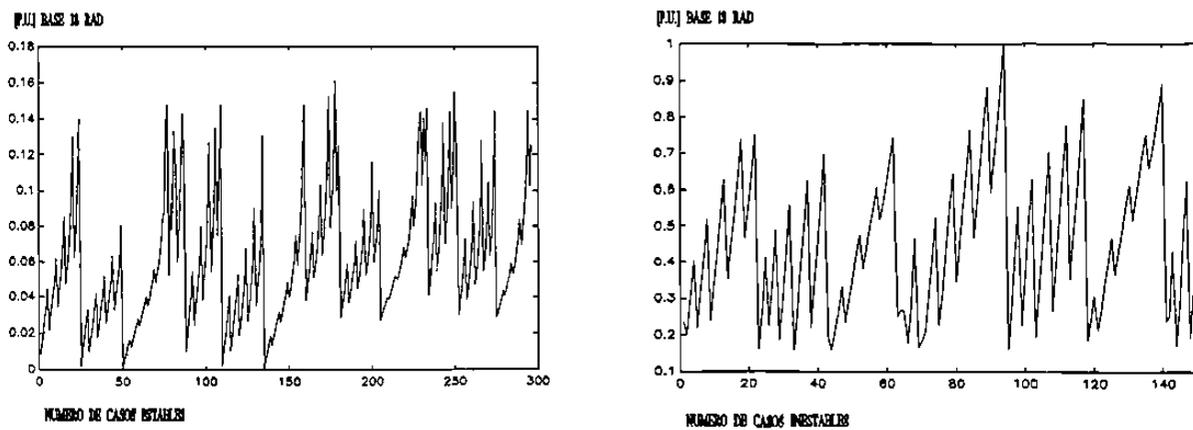


Fig. 5.24 Valores normalizados de diferencia angular. Caso 11.

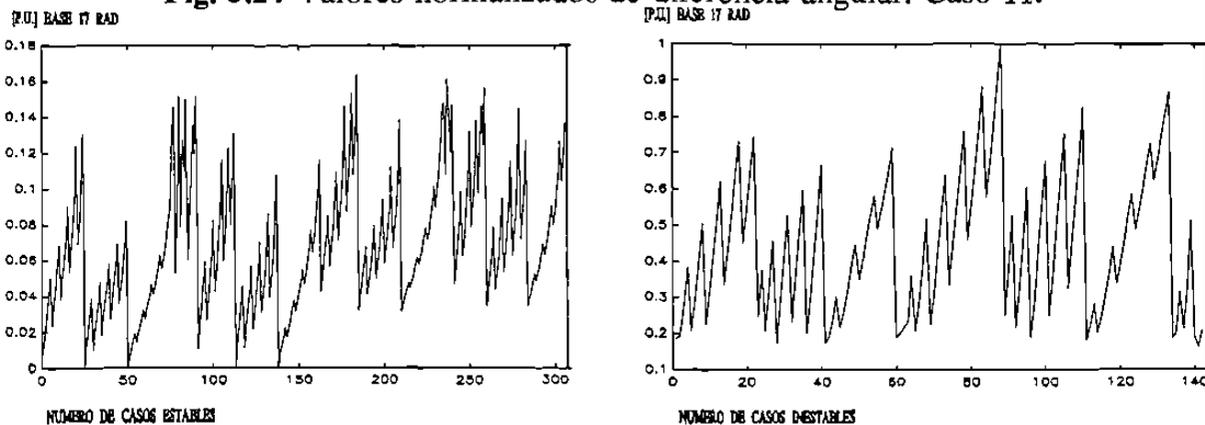


Fig. 5.25 Valores normalizados de diferencia angular. Caso 12.

En este caso la variable de salida toma múltiples valores dentro del intervalo (0,1), por lo que el mapeo que deben realizar las RNA's es mucho más complejo, que el efectuado cuando la variable de salida toma solo los dos valores extremos.

En la Tabla 5.16 se muestran los porcentajes de error de entrenamiento alcanzados por RNA's de uno a diez elementos en la capa interna, después de alrededor de 500 iteraciones del algoritmo de retro-propagación de error. Se utilizaron las 12 variables de entrada descritas en la sección 4.3.1.

Seleccionando las 12 RNA's con errores de entrenamiento mínimos, éstos se encuentran en un rango que va de 0.02% a 0.09%, los que se consideran aceptables.

Tabla 5.16
Errores de Entrenamiento en Redes [%]

RED	Numero de Elementos en la Capa Interna									
	1	2	3	4	5	6	7	8	9	10
1	0.15	0.10	0.10	0.10	0.10	0.11	0.11	0.09 *	0.12	0.10
2	0.13	0.07	0.10	0.07	0.08	0.06 *	0.07	0.07	0.08	0.06
3	0.10	0.05	0.08	0.07	0.03 *	0.06	0.06	0.06	0.05	0.04
4	0.26	0.17	0.09 *	0.14	0.16	0.09	0.16	0.22	0.15	0.14
5	0.05	0.05	0.04	0.03 *	0.04	0.04	0.04	0.03	0.04	0.04
6	0.05	0.04	0.04	0.04	0.03 *	0.03	0.04	0.04	0.03	0.03
7	0.12	0.12	0.07	0.10	0.06 *	0.07	0.07	0.07	0.08	0.07
8	0.14	0.07	0.11	0.06	0.06	0.05 *	0.09	0.08	0.05	0.06
9	0.09	0.06	0.06	0.04 *	0.06	0.05	0.05	0.04	0.04	0.04
10	0.24	0.18	0.15	0.14	0.09 *	0.17	0.13	0.14	0.16	0.10
11	0.05	0.04	0.04	0.03	0.04	0.02 *	0.04	0.04	0.03	0.03
12	0.05	0.04	0.03	0.03	0.03	0.03	0.04	0.03	0.02 *	0.03

Con respecto al desempeño de las RNA's, en la etapa de prueba, la Tabla 5.17 muestra los porcentajes de error obtenidos por cada una de las redes previamente entrenadas.

En este caso, para las redes con errores de entrenamiento mínimo, los porcentajes de error de prueba van desde 0.07% hasta 0.58%, los que se consideran también como valores aceptables.

La Tabla 5.18 muestra los resultados de una serie de pruebas efectuadas a las redes para las que se obtuvo el mínimo error de entrenamiento. En estas pruebas se fija una tolerancia de $\pm 5\%$ en la exactitud con que se obtienen los valores de salida. Se lista el número de patrones que cae fuera de la tolerancia, el porcentaje real de error de las RNA's y la magnitud base del ángulo en grados.

Tabla 5.17
Errores de Prueba en Redes [%]

RED	Numero de Elementos en la Capa Interna									
	1	2	3	4	5	6	7	8	9	10
1	0.79	0.59	0.54	0.76	0.60	0.56	0.67	0.58 *	0.67	0.58
2	0.38	0.32	0.32	0.23	0.17	0.25 *	0.19	0.24	0.13	0.25
3	0.24	0.18	0.23	0.23	0.13 *	0.16	0.12	0.15	0.15	0.14
4	0.27	0.38	0.14 *	0.19	0.25	0.13	0.25	0.28	0.20	0.33
5	0.12	0.12	0.12	0.10 *	0.09	0.10	0.09	0.16	0.11	0.12
6	0.11	0.08	0.12	0.09	0.11 *	0.10	0.08	0.11	0.10	0.07
7	0.49	0.45	0.41	0.52	0.33 *	0.34	0.43	0.40	0.32	0.45
8	0.32	0.30	0.32	0.30	0.24	0.14 *	0.19	0.19	0.17	0.19
9	0.22	0.10	0.17	0.12 *	0.14	0.14	0.13	0.10	0.17	0.12
10	0.23	0.16	0.32	0.15	0.14 *	0.20	0.14	0.22	0.16	0.13
11	0.10	0.09	0.09	0.10	0.13	0.07 *	0.08	0.13	0.10	0.09
12	0.09	0.13	0.10	0.10	0.08	0.14	0.09	0.09	0.08 *	0.08

Tabla 5.18

Patrones con error superior al $\pm 5\%$

RED	DE ENTRENAMIENTO		DE PRUEBA		Pg _{BASE} [GRAD]
	NUM.	% ERROR	NUM.	% ERROR	
1	46	10.27	26	29.55	745
2	24	5.36	37	42.05	1260
3	8	1.79	12	13.64	1146
4	28	6.25	14	15.91	287
5	6	1.34	14	15.91	1031
6	6	1.34	18	20.45	974
7	16	3.57	19	21.59	802
8	18	4.02	13	14.77	1260
9	19	4.24	11	12.50	1146
10	29	6.47	15	17.05	287
11	2	0.45	3	3.41	1031
12	2	0.45	12	13.63	974

Se observa que la magnitud de los porcentajes de error tanto para los patrones de entrenamiento, como para los de prueba, son mayores a las reportadas en las Tablas 5.16 y 5.17. Esto es así debido a que se utiliza un criterio más estricto para evaluar el desempeño de las redes. Sin embargo, para obtener niveles de operación útiles sería necesario ajustarse a criterios aún más estrictos, por ejemplo, basados en una tolerancia angular fija. En este caso la tolerancia angular es variable para cada red, debido a que se tienen diferentes valores base. Por ejemplo, examinando los resultados de la red 11, se observa que se obtiene un 3.41% de error de prueba, lo que indica que el 96.59% de los valores angulares de los patrones de prueba se estiman con una tolerancia dentro de la banda del $\pm 5\%$; lo que corresponde, de acuerdo al valor angular base de 1031 grados, a ± 51.5 grados. Esta tolerancia angular no permite obtener una conclusión

definitiva sobre la estabilidad o inestabilidad de una gran cantidad de casos.

Por otra parte, de acuerdo al desarrollo del proceso de entrenamiento no se observó tendencia a disminuir los errores en caso de aumentar el número de iteraciones.

De estos resultados se concluye que no es recomendable utilizar el valor angular como tal, para estimar la estabilidad, a pesar de que se obtienen porcentajes de error de entrenamiento reducidos. Sin embargo, sí se observa su utilidad como variable principal en el diseño de el índice de estabilidad, el cual por ser una variable binaria es fácilmente procesado por medio de RNA's, como se mostró en el capítulo IV.

5.4 Inclusión de Controles Suplementarios

Como una ayuda para mantener la estabilidad, cuando existen restricciones en la red de transmisión, es común la utilización de controles discretos suplementarios. En el caso de la red bajo estudio, se propone la utilización de un control del tipo de disparo automático de generación (DAG), que actúe únicamente en aquellos casos para los que haya alta probabilidad de pérdida de estabilidad, de conservarse todas las unidades conectadas.

Para las fallas analizadas previamente, es posible utilizar los casos de entrenamiento inestables como nuevos casos de estudio. La nueva condición a considerar para cada uno de estos casos es la operación del DAG, sobre las unidades.

De acuerdo al número de generadores sincronizados, se deberían estudiar varias alternativas. Por ejemplo, si la planta tiene las cuatro unidades en línea, se tendría la posibilidad de disparar una, dos, o tres de ellas, dejando una fuera del esquema del DAG. El número de generadores a desconectar se definiría por la gravedad de la contingencia.

La Figura 5.26 muestra un diagrama simplificado del esquema lógico de operación del control para el disparo automático de las unidades, que se activa al detectar el disparo de alguna de las líneas de transmisión de 400 kV.

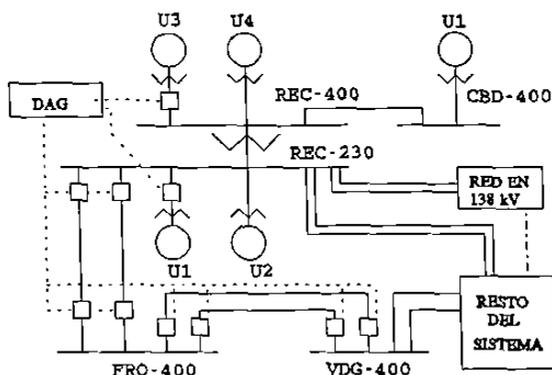


Fig. 5.26 Esquema lógico simplificado de operación del DAG.

Una primera etapa del estudio sería aquella que considere el disparo de solo uno de los generadores: Una de las unidades conectadas a 230 kV (REC-U1), o una de las conectadas a 400 kV (REC-U3).

La activación de estos dos esquemas de DAG genera dos grupos de resultados cada uno, que definen la estabilidad de las unidades restantes. Considere las cuatro unidades de la planta conectadas, y un estudio de estabilidad del cual se concluye la pérdida de sincronismo si no se activa el DAG, ahora:

- a) Si actúa el DAG sobre REC-U1...
 - a.1) ¿Es REC-U2 estable? (REC-U2 se conecta a 230 kV).
 - a.2) ¿Son REC-U3 y REC-U4 estables? (conectadas a 400 kV).

- b) Si actúa el DAG sobre REC-U3...
 - b.1) ¿Son REC-U1 y REC-U2 estables?
 - b.2) ¿Es REC-U4 estable?

De aquí, que si se emplea la metodología de redes de neuronas artificiales se tendría que entrenar a cuatro RNA's para aprender a responder a estas preguntas, para cada tipo de falla.

5.4.1 Nuevos Patrones Necesarios

Considerando el número de casos de entrenamiento estables e inestables, presentados en la Tabla 4.2, se deberían efectuar un total de 1491 nuevos estudios de estabilidad. En realidad este número se reduciría aproximadamente a la mitad debido al traslape entre casos que son inestables tanto para las unidades conectadas a 230 kV como para las unidades en 400 kV.

5.4.2 Resultados de Entrenamiento y Prueba

La factibilidad del método se muestra por medio del entrenamiento y pruebas a cuatro RNA's. Los patrones de entrada/salida se generan con nuevos estudios de estabilidad en el tiempo, en los que se considera la operación de un esquema de disparo automático de generación en un tiempo fijo de 6 ciclos, después de que se libera la falla. Las redes 1 y 2 se entrenan con los resultados obtenidos cuando el esquema DAG opera sobre REC-U1. Las redes 3 y 4, a su vez, se entrenan con los patrones correspondientes a la operación del esquema DAG sobre REC-U3. La falla principal es un corto circuito trifásico en la barra REC-400 (falla 2).

La Tabla 5.19 muestra el número de casos estables e inestables que se proporcionan a cada una de las RNA's, tanto para su entrenamiento, como para prueba.

El total de casos de entrenamiento, para cada red, es de 298, que corresponde al número original de patrones (448) menos 150 casos en que solo se tiene una unidad conectada a cada barra, y en los que no se consideró la operación de DAG.

Tabla 5.19
Número de Casos por Categoría de Clasificación

RED NUM	Casos de Entrenamiento		Casos de Prueba		DAG en unidad
	Estables	Inestables	Estables	Inestables	
1	173	125	32	56	REC-U1
2	171	127	30	58	REC-U1
3	174	124	35	53	REC-U3
4	173	125	35	53	REC-U3

La suma cuadrática de errores de entrenamiento, obtenidos después de 500 iteraciones del proceso de aprendizaje, se muestran en la Tabla 5.20.

Se observa que es posible obtener un porcentaje de error mínimo para cada red menor al 1%, eligiendo el número óptimo de neuronas en la capa interna.

Tabla 5.20
Suma Cuadrática de Errores de Entrenamiento

RED Num	Número de Neuronas en la Capa Interna									
	1	2	3	4	5	6	7	8	9	10
1	1.36	1.06	1.41	1.16	1.26	0.73	0.86	0.77	0.79	1.02
2	1.40	1.40	1.22	1.01	1.06	1.07	1.02	1.05	0.85	0.86
3	0.98	1.04	0.81	0.82	1.10	0.94	0.69	0.84	0.89	0.79
4	1.11	1.09	1.05	0.99	1.11	0.99	1.07	0.73	0.93	0.99

Los errores de prueba se muestran en la Tabla 5.21. Se observa que en todos los casos los porcentajes de error son mayores que los obtenidos en la etapa de entrenamiento.

El número de patrones clasificados erróneamente, en la etapa de prueba, se muestran en la Tabla 5.23.

Si se seleccionan las redes que obtuvieron el mejor desempeño en la etapa de entrenamiento o de prueba (en este caso), se tienen en total 29 patrones mal clasificados, que equivalen a un 8.24% de error global.

Tabla 5.23

Número de Clasificaciones Incorrectas en Etapa de Prueba

RED Num	Número de Neuronas en la Capa Interna									
	1	2	3	4	5	6	7	8	9	10
1	9	9	8	8	9	5 *	5	5	5	5
2	9	11	10	7 *	12	7	11	7	7	7
3	9 **	9	9	9 *	10	9	9	9	9	9
4	8 *	8	8	8	8	8	8	8	8	8

Los 29 patrones mal clasificados se dividen en 24 casos en que un patrón estable es clasificado como inestable y 5 casos en que un patrón inestable se clasifica como estable. El primer tipo de errores es tolerable, pero se debe tratar de evitar al máximo la ocurrencia de errores del segundo tipo. Esto se podría lograr reforzando el aprendizaje.

Los resultados obtenidos muestran que es posible aplicar la metodología de redes de neuronas artificiales a los casos en que se considera la activación de controles suplementarios.

5.5 Sistema de Consulta Basado en RNA's

Teniendo como base las RNA's entrenadas para clasificar casos estables e inestables se plantea la posibilidad de construir un sistema interactivo, basado en conocimiento que actúe ya sea en línea auxiliando al personal de operación de los centros de control, en la toma de decisiones o fuera de línea, en modo de entrenamiento. Incorporando el conocimiento referente a la acción de controles suplementarios se puede dar un panorama completo del curso de acción de los disturbios más graves.

5.5.1 Modo de Funcionamiento en Línea

Para el funcionamiento en línea de un sistema basado en conocimiento, se debe considerar la realización de algunas funciones de manera automática. La principal de ellas es la recolección de las variables de entrada. El sistema debe tener comunicación con equipos de supervisión de la red eléctrica, los que le informen del estado del sistema: Los cambios a la demanda, cambios en la generación y en el número de unidades conectadas a la planta, cambios en la topología y la posición angular inicial. Se considera una buena opción tomar estos valores de un estimador de estado.

La salida del sistema puede ser gráfica o en modo texto. La salida gráfica se considera más adecuada pues mostraría patrones de estabilidad, señalando claramente la posición actual con referencia al hiperplano que separa los casos estables de los inestables. Esto es, indicaría al operador que tan cerca o lejos está el sistema eléctrico de la zona de inestabilidad. La salida en modo texto se contempla como una indicación puntual, que diga simplemente si el sistema es o no estable en la condición actual.

5.5.2 Modo de Funcionamiento para Entrenamiento

Esta forma de operación del sistema basado en conocimiento se considera útil

para el entrenamiento del personal de operación, como preparación ante contingencias conocidas que hayan derivado en colapsos, o que pueden llegar a serlo. En el caso ideal se debe contar con equipo para simular el ambiente de una sala de operación y programas de simulación adecuados para reconstruir la situación deseada. Sin embargo, el propósito se cumple si se cuenta simplemente con un simulador de flujos de potencia, con el que se planteen los casos base a estudiar, del cual se puedan extraer las variables de entrada a las RNA's.

5.6 Sistema en Línea para la Supervisión y Selección de Controles Suplementarios

A medida que crece el sistema de potencia, se hace mayor la complejidad de su operación. Al aumentar el número de controles disponibles, se debe considerar una cuidadosa coordinación en su activación, para reducir al mínimo o eliminar la posibilidad de acciones contraproducentes, que lleven al sistema eléctrico a situaciones peores a las que se trata de evitar.

Considere el caso de la red eléctrica bajo estudio. En los casos simplificados planteados en la sección 5.4, ya se tienen dos alternativas para elegir: Se dispara la unidad conectada a 230 kV o la conectada a 400 kV. Una errónea selección puede llevar a la salida de operación de toda la planta. Es posible que ante la falla A, lo mejor sea disparar REC-U1, pero si ocurre la falla B la mejor opción es disparar REC-U3. La decisión final debe ser tomada un instante después de ocurrir la falla por un sistema automático que sea capaz de distinguir la diferencia entre falla A y falla B.

5.6.1 Variables de Entrada-Salida

En este caso, además de las variables de estado estable con que se ha trabajado hasta ahora, se requiere información dinámica. Se requiere medir la gravedad de la contingencia, comparando por ejemplo la diferencia entre las potencias activas de previas, durante y de posteriores a la falla, los cambios de velocidad y/o aceleración de

las unidades de la planta y si es posible los cambios angulares en los rotores. También es importante considerar los cambios de topología en la red asociada a la planta, al ocurrir el disturbio.

La variable de salida puede ser también el índice de estabilidad, aunque la velocidad de procesamiento para este caso debe ser mayor, pues se deben analizar, (al menos en este caso), dos alternativas y elegir aquella que indique mayores posibilidades de obtener estabilidad.

5.7 Ejemplo de Aplicación

La utilización del sistema interactivo en modo de entrenamiento, requiere que el personal decida las condiciones de operación bajo las cuales se realizará el análisis rápido de estabilidad. Para su utilización en modo en línea se deberá contar con medición de las variables de entrada:

- a) Número de unidades sincronizadas en la planta.
- b) Topología
- c) Demanda global del sistema eléctrico

El análisis de estabilidad se efectúa eligiendo una cierta falla, de entre las seis posibles, de acuerdo al nivel de seguridad con que se desee operar. El nivel de seguridad será alto si se elige una falla crítica; y cuando se utilice una falla menos severa para fijar las condiciones de generación de la planta, se obtendrá un nivel de seguridad más bajo que en el primer caso.

Supóngase que se eligen, o se tienen, las siguientes condiciones de estado estable:

- Planta operando con 4 unidades.
- Línea FRO-VDG fuera de operación.
- Demanda máxima.

Se selecciona la falla 2 que es una de las más severas; Falla trifásica en REC-400, liberada con el disparo de una línea REC-FRO.

La respuesta del sistema ante esta selección de variables consiste en desplegar en la pantalla un espacio de generación en el que se muestran claramente los puntos de operación estables e inestables, si ocurre la falla elegida, Figura 5.27. Si se desea operar el sistema previendo esta contingencia, la generación total de la planta debe ser menor a 900 MW.

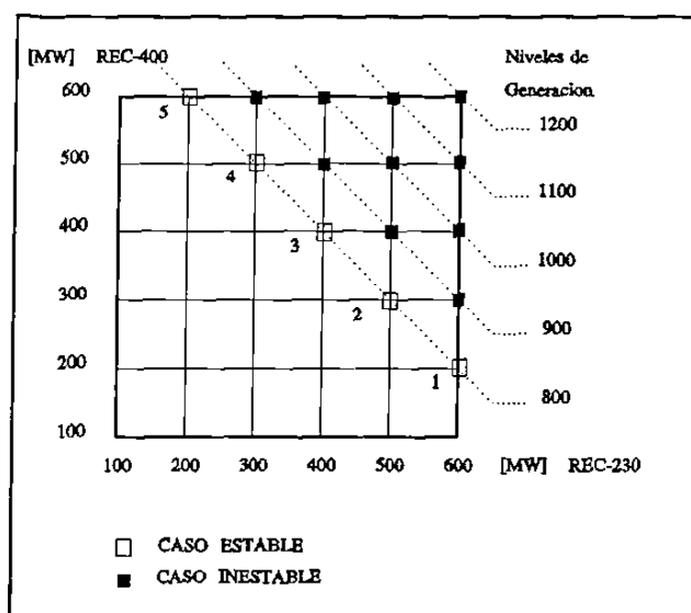


Fig. 5.27 Espacio de generación sin activación de DAG.

Los puntos de máxima generación segura (1-5) indican la generación máxima que se debe asignar a las unidades si se desea que la planta mantenga sincronismo, en caso de ocurrir la falla analizada, y sin que haya controles suplementarios activados. La generación segura máxima es de 800 MW como se observa en la Fig. 5.27.

Suponiendo que es indispensable elevar la generación en la planta, por restricciones en otras áreas, y que la nueva potencia generada excede los límites de seguridad de la Fig. 5.27; es necesario plantear la activación de un esquema de control del tipo de disparo automático de generación.

El siguiente paso del análisis es la selección del esquema adecuado, de entre los dos disponibles:

a) Disparo de REC-U1 (unidades en 230 kV)

b) Disparo de REC-U3 (unidades en 400 kV)

El sistema presenta las dos opciones y al elegir cualquiera de ellas muestra un nuevo espacio de generación en el que se han movido los límites de operación. El esquema a utilizar será aquel en el que se logre que el punto de máxima generación permanezca fuera de las zonas inestables. La Figura 5.28 muestra el espacio de generación obtenido cuando el esquema DAG activa el disparo de REC-U1.

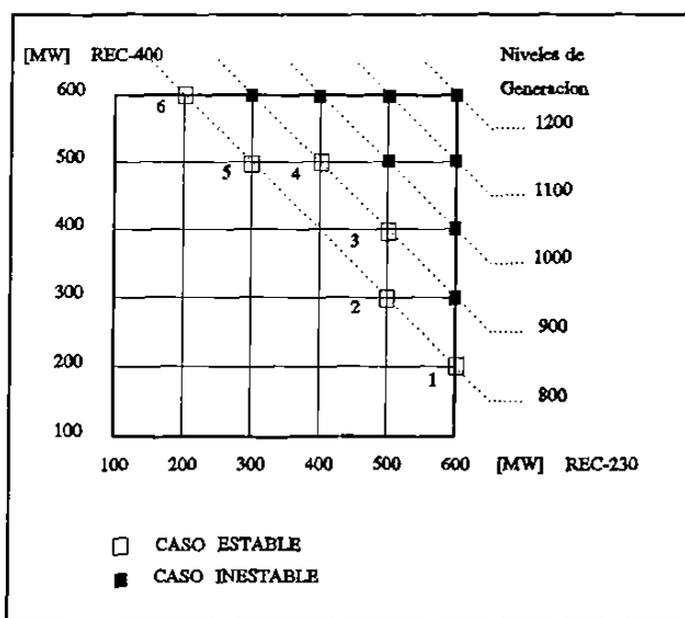


FIG.5.28 Espacio de generación para DAG en REC-U1.

En este caso es recomendable operar en el punto de generación 4, ya que el esquema DAG dispararía REC-U1 con una generación de 200 MW, quedando disponibles en la planta 700 MW en tres unidades.

La Figura 5.29 muestra el espacio de generación cuando el esquema DAG opera sobre REC-U3.

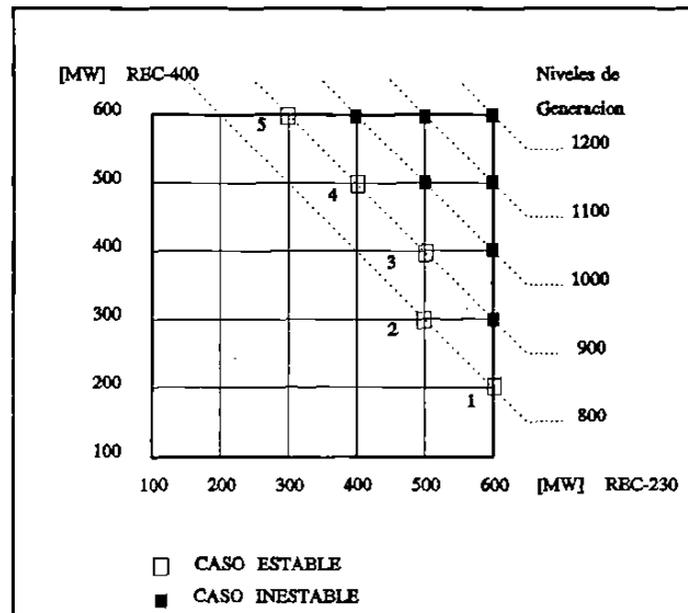


Fig. 5.29 Espacio de generación para DAG en REC-U3

La recomendación en este caso sería operar en el punto de generación 3, ya que el esquema DAG dispararía REC-U3 con una generación de 200 MW y se tendrían aún 700 MW en las unidades restantes.

Esto indica que para las condiciones planteadas, es posible seleccionar cualquiera de las dos opciones, tratando de minimizar la pérdida de generación necesaria para mantener sincronismo.

5.8 Desarrollo del Sistema Basado en RNA's

En esta sección se presentan en forma condensada los pasos que se consideran necesarios para lograr la implementación del sistema propuesto. No es requisito indispensable, sin embargo es deseable que el personal encargado del desarrollo de un sistema de esta naturaleza esté ligado al área de análisis de la operación, o tenga

conocimiento de los problemas operativos.

El desarrollo del sistema consta de las siguientes etapas:

- 1 Selección o identificación de la(s) planta(s) generadora(s) a incluir dentro de la base de conocimiento.
- 2 Planeación de la base de conocimiento: Selección de fallas a analizar, condiciones topológicas y niveles de demanda a considerar etc.
- 3 Elaboración del espacio de generación más adecuado para mostrar los patrones de estabilidad. Selección de los niveles de generación a considerar.
- 4 Realización de las simulaciones de estabilidad en el tiempo necesarias para conformar las bases de datos de entrenamiento y de prueba.
- 5 Organización de los patrones entrada-salida por tipo de falla.
- 6 Selección del tipo de RNA a utilizar.
- 7 Entrenamiento y prueba de las RNA's.
- 8 Formación del sistema en base a las RNA's con mejor desempeño.
- 9 Implementación física en el equipo disponible.

Se considera necesario contar con un estimador de estado o con mediciones confiables de las variables de entrada.