

**MODELADO DE LA MÁQUINA SÍNCRONA MEDIANTE REDES
NEURONALES**

RENÉ ALEXANDER BARRERA CÁRDENAS

UNIVERSIDAD INDUSTRIAL DE SANTANDER

FACULTAD DE INGENIERÍAS FÍSICO – MECÁNICAS

**ESCUELA DE INGENIERÍA ELÉCTRICA ELECTRÓNICA Y DE
TELECOMUNICACIONES**

BUCARAMANGA

2010

MODELADO DE LA MÁQUINA SÍNCRONA MEDIANTE REDES NEURONALES

RENÉ ALEXANDER BARRERA CÁRDENAS

Tesis de grado para optar al título de Magister en Ingeniería Eléctrica

Director

HERMANN RAÚL VARGAS TORRES

Doctor Ingeniero Electricista

UNIVERSIDAD INDUSTRIAL DE SANTANDER

FACULTAD DE INGENIERÍAS FÍSICO – MECÁNICAS

**ESCUELA DE INGENIERÍA ELÉCTRICA ELECTRÓNICA Y DE
TELECOMUNICACIONES**

BUCARAMANGA

2010

Índice general

1. Introducción	1
1.1. Planteamiento del problema	1
1.2. Objetivos	3
1.3. Organización de la memoria	4
2. Generalidades	5
2.1. Análisis de la estabilidad de ángulo ante una gran perturbación en sistemas eléctricos de potencia	5
2.2. Métodos de análisis para la simulación en el dominio del tiempo	7
2.2.1. Solución particionada con integración explícita	8
2.2.2. Solución simultánea con integración implícita	9
2.3. Redes neuronales Artificiales - Perceptrón multicapa	11
2.3.1. Aspectos Básicos	12
2.3.2. Estrategia básica de ajuste del MLP	13
2.3.2.1. Selección de las entradas y extracción de las características . . .	13
2.3.2.2. Definición de los datos de entrenamiento	13
2.3.2.3. Selección de la ANN	13
2.3.2.4. Entrenamiento de la ANN	13
2.3.2.5. Prueba	14
3. Redes Neuronales aplicadas al modelado de la máquina síncrona	15
3.1. Modelado de la máquina síncrona	15
3.2. Métodos Tradicionales	17
3.3. Estimación de parámetros de la máquina síncrona	17
3.4. Representación de la dinámica de la máquina síncrona: modelo de caja negra . . .	19
3.5. Otras técnicas de inteligencia artificial empleadas en el modelado de la máquina síncrona	22
4. Modelo neuronal de la máquina síncrona para estudios de estabilidad	23
4.1. Modelo neuronal clásico de la máquina síncrona	23

4.1.1. Modelo clásico de la máquina síncrona	23
4.1.2. Desarrollo del modelo neuronal clásico	25
4.2. Modelo neuronal de quinto orden de la máquina síncrona	26
4.2.1. Modelo de quinto orden de la máquina síncrona	27
4.2.2. Desarrollo del modelo neuronal de quinto orden	28
4.3. Modelo neuronal de octavo orden de la máquina síncrona	33
4.3.1. Modelo de octavo orden de la máquina síncrona	33
4.3.2. Desarrollo del modelo neuronal de octavo orden	33
4.4. Definición de la arquitectura del modelo neuronal	35
5. Pruebas y Resultados	41
5.1. Resultados obtenidos del modelo neuronal clásico	41
5.2. Resultados Obtenidos del modelo neuronal de quinto orden	47
5.3. Resultados Obtenidos del modelo neuronal de octavo orden	48
5.4. Caso de estudio: Efecto del sistema de excitación.	48
6. Conclusiones, aportaciones y sugerencias para posteriores desarrollos	62
6.1. Resumen y conclusiones	62
6.2. Aportaciones originales	63
6.3. Sugerencias para posteriores desarrollos	64
A. Modelo general de la máquina síncrona en el análisis de estabilidad transitoria	65
A.1. Representación de la máquina síncrona	65
A.1.1. Ecuaciones de la dinámica de movimiento	66
A.1.2. Ecuaciones del circuito del rotor	66
A.1.3. Ecuaciones de tensión del estator	67
A.1.4. Saturación magnética	69
A.2. Representación del sistema de excitación	71
Bibliografía	74

Índice de figuras

2.1. Red Neuronal típica con una capa oculta	12
3.1. Estimación de parámetros de la máquina síncrona.	18
3.2. Esquema empleado en [Park et al., 2002] para la identificación en línea de la dinámica no lineal del generador síncrono	20
4.1. Modelo clásico de la máquina síncrona	24
4.2. Red neuronal artificial propuesta para el modelo neuronal clásico	26
4.3. Circuito equivalente de la máquina síncrona despreciando el efecto de los polos salientes en el periodo subtransitorio.	27
4.4. Circuito propuesto para la representación de la máquina síncrona	28
4.5. Esquema de excitación AVR simplificado como modelo tipo caja negra	29
4.6. Red Neuronal propuesta para el modelo neuronal de quinto y octavo orden de la máquina síncrona.	31
4.7. Red Neuronal propuesta para el sistema de excitación AVR	32
4.8. Modelo Neuronal de Quinto Orden Completo (Máquina + AVR)	32
4.9. Esquema de excitación AVR y PSS simplificado como modelo tipo caja negra	33
4.10. Red Neuronal propuesta para el sistema de excitación AVR con PSS	36
4.11. Modelo Neuronal de Octavo Orden Completo (Máquina + AVR con PSS)	36
4.12. Desempeño de las arquitecturas del modelo neuronal clásico	38
4.13. Velocidad de convergencia del modelo Neuronal Clásico	39
4.14. Desempeño arquitecturas modelo neuronal de quinto orden	39
4.15. Desempeño arquitecturas modelo neuronal de octavo orden	40
5.1. Sistema de una máquina conectado a una barra infinita	41
5.2. Desempeño del Modelo Neuronal Clásico ante las diferentes épocas de entrenamiento	43
5.3. Comparación de la estimación del Ángulo del rotor para un caso estable (Modelo Clásico)	44
5.4. Detalle de la comparación de la estimación del Ángulo del rotor para un caso es- table (Modelo Clásico)	44

5.5. Comparación de la estimación del Ángulo del rotor para un caso críticamente estable (Modelo Clásico)	45
5.6. Detalle de la comparación de la estimación del Ángulo del rotor para un caso críticamente estable (Modelo Clásico)	45
5.7. Comparación de la estimación del Ángulo del rotor para un caso inestable (Modelo Clásico)	46
5.8. Detalle de la comparación de la estimación del Ángulo del rotor para un caso inestable (Modelo Clásico)	46
5.9. Ángulo del rotor. Despeje de falla 20 [ms].	49
5.10. Tensión en terminales. Despeje de falla 20 [ms].	50
5.11. Tensión de excitación. Despeje de falla 20 [ms].	50
5.12. Potencia Activa. Despeje de falla 20 [ms].	51
5.13. Ángulo del rotor. Despeje de falla 60 [ms].	51
5.14. Tensión en terminales. Despeje de falla 60 [ms].	52
5.15. Tensión de excitación. Despeje de falla 60 [ms].	52
5.16. Potencia Activa. Despeje de falla 60 [ms].	53
5.17. Ángulo del rotor. Despeje de falla 30 [ms].	53
5.18. Tensión en terminales. Despeje de falla 30 [ms].	54
5.19. Potencia activa. Despeje de falla 30 [ms].	54
5.20. Tensión de excitación. Despeje de falla 30 [ms].	55
5.21. Ángulo del rotor. Despeje de falla 80 [ms].	55
5.22. Tensión en terminales. Despeje de falla 80 [ms].	56
5.23. Potencia activa. Despeje de falla 80 [ms].	56
5.24. Tensión de excitación. Despeje de falla 80 [ms].	57
5.25. Comparación Ángulo del Rotor para los diferentes sistemas de Excitación. a) Modelos neuronales. b) Figura E13.7(a) de [Kundur, 1994]	58
5.26. Comparación: Potencia Activa para los diferentes sistemas de Excitación. a) Modelos neuronales. b) Figura E13.7(b) de [Kundur, 1994]	59
5.27. Comparación: Tensión en Terminales para los diferentes sistemas de Excitación. a) Modelos neuronales. b) Figura E13.7(c) de [Kundur, 1994]	60
5.28. Comparación: Tensión de Excitación para los diferentes sistemas de Excitación. a) Modelos neuronales. b) Figura E13.7(d) de [Kundur, 1994]	61
A.1. Circuito amortiguador equivalente del eje directo	66
A.2. Circuito amortiguador equivalente de eje en cuadratura	66
A.3. Característica de Saturación	70
A.4. Sistema de excitación con AVR y PSS	72
A.5. Sistema de excitación Regulador de Voltaje Automático (AVR)	73

Lista de tablas

4.1. Definición de la Arquitectura de los modelos neuronales propuestos.	39
5.1. Parámetros del generador - Modelo de quinto orden	48
5.2. Parámetros del sistema de excitación con AVR	48
5.3. Parámetros del generador - Modelo octavo orden	48
5.4. Parámetros del sistema de excitación con AVR con PSS	48

RESUMEN

TITULO:

MODELADO DE LA MÁQUINA SÍNCRONA MEDIANTE REDES NEURONALES*

AUTOR:

RENE ALEXANDER BARRERA CARDENAS**

PALABRAS CLAVES:

Máquina Síncrona, Estabilidad transitoria, estabilidad de ángulo, redes neuronales artificiales (RNA), perceptron multicapa.

DESCRIPCION:

En este trabajo de grado se proponen modelos de regresión neuronal, de tipo caja negra, que repliquen el comportamiento de los modelos de la máquina síncrona, basados en ecuaciones de Park, que se utilizan en el estudio de estabilidad transitoria de ángulo ante grandes perturbaciones. Para la implementación de los modelos de regresión neuronal se utilizan redes neuronales del tipo perceptron multicapa (MLP).

Los registros obtenidos de simulaciones en el dominio del tiempo realizados sobre un sistema de potencia básico (generador conectado a un barraje infinito), son usados para crear una base de datos de entrenamiento y posteriormente validar la metodología basada en redes neuronales artificiales propuesta para la estimación de las principales variables de la máquina síncrona. Se presentan funciones de regresión para tres modelos de la máquina síncrona: el modelo clásico, un modelo de quinto orden que incluye un regulador de voltaje automático (AVR) como sistema de excitación y un modelo de octavo orden equipado con un sistema de excitación del tipo AVR con sistema estabilizador de potencia (PSS).

Según los resultados obtenidos, los modelos neuronales presentan una alta adaptación al modelo clásico de la máquina síncrona y una adaptación aceptable a los modelos de orden superior, lo cual muestra la validez de la estrategia, su posible uso para estudios de estabilidad sobre la máquina síncrona y la posibilidad de adaptar otras de técnicas de inteligencia artificial más elaboradas con el fin de obtener un mejor ajuste de los modelos neuronales.

* Proyecto de Grado Maestría

**Facultad de Ingenierías Físico-Mecánicas. Escuela de Ingeniería Eléctrica, Electrónica y Telecomunicaciones.
Dr. Hermann Raúl Vargas Torres.

ABSTRACT

TITLE:

SYNCHRONOUS MACHINE MODELING USING NEURAL NETWORKS*

AUTHOR:

RENE ALEXANDER BARRERA CARDENAS**

KEY WORDS:

Synchronous machine, transient stability, angle stability, artificial neural networks (ANNs), multilayer perceptron

DESCRIPCION:

In this paper grade is proposed neural regression models, black box, that replicate the behavior of the synchronous machine models, based on Park's equations, which are used in the study of transient angle stability to large perturbations. To implement neural regression models are used neural networks of multilayer perceptron (MLP).

Records obtained from simulations in the time domain performed on a basic power system (generator connected to an infinite busbar) are used to create a database of training and further validate the methodology based on artificial neural networks proposed for estimating the main variables of the synchronous machine. Regression functions are presented for three models of the synchronous machine: the classical model, a fifth-order model that includes an automatic voltage regulator (AVR) and excitation system and an eighth order model equipped with a type excitation system AVR with power system stabilizer (PSS).

According to the results, the neural models show a high adaptation to the classic model of the synchronous machine and an acceptable adjustment to the higher-order models, which shows the validity of the strategy, its possible use for stability studies on the synchronous machine and the possibility of adapting other techniques more sophisticated artificial intelligence in order to obtain a better fit of neural models.

* Degree project

**Faculty of Physical-Mechanical Engineering. School of Electrical Engineering, Electronics and Telecommunications. Hermann Raúl Vargas Torres..

Capítulo 1

Introducción

En este capítulo inicial, se presenta la temática a abordar en esta tesis, así como los objetivos de la misma. También se describe la organización del texto.

1.1. Planteamiento del problema

Las máquinas síncronas son ampliamente utilizadas en el sector industrial y juegan un papel muy importante en la estabilidad de los sistemas de potencia. Un modelo apropiado para la máquina síncrona es esencial para un análisis válido de estabilidad y funcionamiento dinámico del sistema. Casi ocho décadas después de la primera publicación en esta área [Kilgore, 1931; Wright, 1931], el tema aun sigue siendo una materia de investigación atractiva y desafiante.

Muchos modelos de la máquina síncrona han sido desarrollados a través de los años empleando diversas aproximaciones y enfoques para soslayar principalmente la sobrecarga computacional asociada a la compleja dinámica y no linealidad inherentes a la representación a gran escala. Probablemente el modelo más simple disponible de la máquina síncrona empleado para estudios de estabilidad [Grainger y Stevenson, 1995; Kundur, 1994], es el que describe una sola máquina síncrona conectada a una barra infinita, basado en la ecuación de oscilación, utilizando el ángulo de oscilación y la velocidad del rotor como variables de estado. Un modelo de descomposición de flujo, el cual incluye una o más variables de estado, adicionalmente a las variables de estado empleadas en la ecuación de oscilación, fue ampliamente utilizado por [DeMarco y Qian, 1986]. Sin embargo, cuando es necesario un incremento en la complejidad de la representación, comúnmente se utiliza un modelo de cinco o siete variables de estado para una máquina síncrona trifásica. [Fitzgerald et al., 1990]

El comportamiento del sistema se puede determinar por dos conjuntos de ecuaciones, uno corresponde con la dinámica de las máquinas del sistema y se define por ecuaciones diferenciales, el otro corresponde con la interconexión de los elementos de la red definido por ecuaciones algebraicas no lineales. Los dos conjuntos de ecuaciones (diferenciales asociadas a los elementos

dinámicos y algebraicas asociadas a la red) forman un sistema algebraico-diferencial de primer orden. Este debe ser resuelto a partir de unas condiciones iniciales para obtener la respuesta en el tiempo del sistema. El análisis de gran perturbación es complejo desde el punto de vista computacional debido a los grandes sistemas de ecuaciones que deben ser resueltos utilizando pasos de tiempo pequeños para evitar errores y problemas de estabilidad numérica. El número de ecuaciones diferenciales (estados) utilizadas para describir la dinámica de cada generador puede ser de hasta varias decenas (generalmente se utiliza un mínimo de 2), dependiendo del modelo empleado para la máquina misma y sus controles. El acoplamiento de cada generador con la red se representa por medio de ecuaciones algebraicas que describen condiciones de frontera. La representación de la red por medio de ecuaciones algebraicas es posible debido a que se desprecia el efecto de los transitorios electromagnéticos (tanto en el sistema de transmisión como en el estator de las máquinas) cuya dinámica es más rápida que la de los transitorios electromecánicos de interés en estudios de estabilidad transitoria de ángulo. Se supone que la red pasa de un estado estacionario a otro en una evolución cuasiestática. La validez de tales suposiciones se justifica con base en la comparación de los resultados obtenidos en las simulaciones con los monitoreados durante perturbaciones en sistemas reales. [Sierra, 2003; Sierra, 2007; Kundur, 1994]

El número de ecuaciones del sistema algebraico-diferencial es generalmente grande y muy disperso (cuasi-vacío). Por ejemplo, si hay 15 ecuaciones diferenciales por cada generador y 2 ecuaciones por barra (debido a que las tensiones y corrientes son fasores y las partes real e imaginaria son separadas para resolver las ecuaciones) entonces un sistema con 2000 barras y 300 generadores genera un sistema de 8500 ecuaciones, 4500 ecuaciones diferenciales ordinarias no lineales de primer orden y 4000 ecuaciones algebraicas no lineales.[Sierra, 2007]

Modelos simples de la máquina son buenos para propósitos de análisis académico pero no lo suficientemente exactos para predecir el desempeño de la máquina en aplicaciones reales para propósitos de control y evaluación de estabilidad en sistemas de potencia. En tales situaciones, las no linealidades en la máquina, a causa de los efectos de saturación y flujo ligado, deben ser incluidos en el modelo de la máquina [Anderson y Fouad, 1997; Kundur, 1994]. Estudios más completos sobre las propiedades de la máquina síncrona, los cuales detallan el modelo de los excitadores, proporcionan modelos más completos y complicados que están siendo cada vez más desarrollados para proveer una representación cada vez más exacta. Desafortunadamente, a medida que la complejidad en los modelos aumenta, estos se hacen inapropiados para aplicaciones en línea y en tiempo real.[yuen Chow y Thomas, 1989]

Uno de los métodos convencionales para la evaluación de estabilidad transitoria de ángulo es la simulación numérica en el dominio del tiempo. Este método consiste en la simulación del comportamiento del sistema de potencia, durante y después de una falla, para una perturbación dada, observando la oscilación del ángulo electromecánico durante unos pocos segundos. Se utiliza para estimar el estado de estabilidad y proporcionar información detallada de la operación de sistemas fallados como punto de referencia. Sin embargo, el método de simulación no es práctico para la

evaluación de estabilidad transitoria de ángulo online principalmente por su alto consumo de tiempo computacional.

El método directo es otra estrategia comúnmente utilizada para la evaluación de estabilidad transitoria de ángulo, el cual reemplaza la integración numérica del sistema de ecuaciones después de la falla por un criterio de estabilidad [Pavella et al., 2000]. Aunque es atractivo para la evaluación de estabilidad transitoria de ángulo, la función que debe encontrarse para definir el criterio de estabilidad presenta un gran reto y adicionalmente este método siempre tiende a dar resultados conservadores, lo cual hace a este método deficiente.

Dadas las limitaciones en el dominio del tiempo y el método directo, surge gran interés en buscar otras alternativas. La existencia de aplicaciones basadas en técnicas de inteligencia artificial para problemas del sector eléctrico fue un punto de referencia para esta investigación [Barrera et al., 2007a; Mora, 2006; Morales y Gómez, 2005; Morales et al., 2006; Morales et al., 2009; Morales et al., 2007b; Park et al., 2005; Ye et al., 2006; Barrera et al., 2007b; Morales et al., 2007a]. La idea de las redes neuronales originada en la década de los cuarenta, ha sido ampliamente empleada en aplicaciones industriales y mas específicamente en el modelado de la máquina síncrona demostrando que son una alternativa viable para la solución del problema en cuanto a exigencia computacional como también complejidad del modelo [yuen Chow y Thomas, 1989; Teeuwsen et al., 2004]. Esta investigación, plantea y estudia el uso de esta metodología, basada en aprendizaje supervisado, para la representación del modelo de la máquina síncrona y su aplicación en la evaluación de estabilidad transitoria de ángulo de sistemas de potencia, mostrando que es una alternativa viable para aplicaciones en tiempo real, con el objeto de proveer métodos que permitan al administrador del sistema eléctrico evaluar posibles condiciones de inestabilidad y poder aplicar los correctivos necesarios a tiempo. [Park et al., 2005]

1.2. Objetivos

El objetivo general de este trabajo de grado es emplear redes neuronales para representar el modelo de la máquina síncrona, basado en ecuaciones de Park, que se utiliza en estudios de estabilidad transitoria.

Para llevar a cabo el objetivo general relacionado con el modelado de la máquina síncrona para estudios de estabilidad transitoria de ángulo, se proponen los siguientes objetivos específicos:

- Definir y entrenar una red neuronal que replique el modelo clásico de la máquina síncrona.
- Reproducir el comportamiento del modelo de quinto orden de la máquina síncrona con redes neuronales.
- Reproducir el comportamiento del modelo de octavo orden de la máquina síncrona con redes neuronales.

- Aplicar los modelos de la máquina síncrona hallados con redes neuronales al estudio de estabilidad de gran perturbación de sistemas de potencia con cargas constantes.

1.3. Organización de la memoria

El texto está organizado en 6 capítulos y un apéndice. El capítulo 2 pretende contextualizar al lector dentro del marco de referencia de esta investigación, detalla el fenómeno de estabilidad transitoria de ángulo, la simulación en el dominio del tiempo y especificaciones de la técnica de inteligencia artificial basada en redes neuronales utilizada en esta investigación.

El capítulo 3 revisa trabajos referentes al empleo de la redes neuronales en la representación de la dinámica no lineal de la máquina síncrona en el sector eléctrico.

El capítulo 4 detalla la metodología propuesta para la adaptación de redes neuronales al estudio de estabilidad transitoria de ángulo.

El capítulo 5 presenta los resultados numéricos obtenidos con la metodología propuesta y los compara con los obtenidos con un paquete de simulación empleado para el estudio de estabilidad transitoria, también se incluye un pequeño análisis de tales resultados.

El capítulo 6 expone las conclusiones y aportaciones de este trabajo de grado y algunas sugerencias para posteriores desarrollos.

Finalmente, el texto se complementa con el apéndice A, que especifica en detalle los modelos de la máquina síncrona mapeados por la red neuronal.

Capítulo 2

Generalidades

El objetivo del presente capítulo es revisar los conceptos básicos asociados al contexto de esta investigación, en primer lugar se define el fenómeno de estabilidad de gran perturbación de sistemas eléctricos de potencia y los métodos de análisis que se utilizan en el dominio del tiempo; finalmente se presentan las características básicas de la técnica de inteligencia artificial empleada en este trabajo de investigación.

2.1. Análisis de la estabilidad de ángulo ante una gran perturbación en sistemas eléctricos de potencia

Los sistemas eléctricos de potencia han presentado un gran desarrollo en los últimos años debido al crecimiento de la población y a la necesidad de brindar un servicio eficiente y de mejor calidad. Los generadores síncronos no han sido ajenos a esta evolución, teniendo en cuenta que desempeñan un papel importante dentro del sistema. Razón por la cual, ha sido necesario estudiar su comportamiento bajo operación en estado estable y transitorio, a través de modelos apropiados para la máquina, con el fin de realizar análisis válidos de estabilidad. Casi ocho décadas después de la primera publicación en esta área el tema aun sigue siendo una atractiva y desafiante materia de investigación [Kilgore, 1931; Wright, 1931].

El análisis de gran perturbación estudia la respuesta de los elementos dinámicos del sistema de potencia (generadores, cargas, elementos de compensación dinámicos, enlaces de corriente continua, etc) y la variación de las diferentes magnitudes de la red (tensiones, flujos por las líneas, frecuencia, etc) ante la ocurrencia de perturbaciones severas y repentinas tales como cortocircuitos, pérdidas de generación ó pérdidas de carga. Bajo condiciones normales de operación, un sistema eléctrico de potencia se encuentra casi en equilibrio, experimenta sólo desviaciones menores causadas por variaciones pequeñas, casi continuas, en la demanda. Cuando una perturbación severa y repentina tiene lugar, hay cambios casi instantáneos en las condiciones iniciales. La respuesta del sistema a este tipo de eventos está altamente influenciada por su carácter no lineal e involucra

grandes variaciones en los ángulos de los rotores y otras magnitudes del sistema.

El análisis de gran perturbación es primordial dentro de los estudios de estabilidad durante la operación y planeación de sistemas eléctricos de potencia. En las últimas décadas los avances en la teoría de control, métodos numéricos y herramientas computacionales han permitido la elaboración de programas muy poderosos que hacen posible el análisis de sistemas de gran dimensión y poseen capacidad para modelar detalladamente todos los elementos dinámicos del sistema.

Los problemas de estabilidad de gran perturbación han sido solucionados a través del uso de sistemas de protección rápidos, confiables y selectivos, sistemas de excitación rápidos y de elevadas ganancias, condensadores en serie y otras técnicas especiales. Como se mencionó anteriormente, la instalación de sistemas de excitación rápidos y de elevadas ganancias mejora la estabilidad de gran perturbación, pero introduce un amortiguamiento negativo a las oscilaciones electromecánicas, lo que puede causar inestabilidad de tipo oscilatorio. Este problema ha sido mitigado con el uso de estabilizadores del sistema de potencia, que son controles auxiliares incluidos en el sistema de excitación con el objeto de amortiguar las oscilaciones regulando la tensión de campo y produciendo con ello un torque electromagnético en fase con la desviación de velocidad rotórica. El desempeño de los diversos controles del sistema ante grandes perturbaciones se evalúa mediante la simulación en el dominio del tiempo, esto permite hacer reajustes si se necesitan, con el fin de mejorar la respuesta del sistema. [Koester et al., 1992; Kundur, 1985; Kundur, 1994]

La estabilidad de gran perturbación está incluida dentro de la categoría más general de estabilidad de ángulo. El estudio de la estabilidad de ángulo de un sistema eléctrico de potencia tiene como objetivo principal determinar si ante la ocurrencia de una perturbación los generadores del sistema permanecen en sincronismo. La estabilidad de gran perturbación también está dentro de la categoría de análisis de corto plazo, debido a que las dinámicas que influyen en la respuesta del sistema en el período de tiempo de interés así lo determinan; estas dinámicas son las de los circuitos del rotor y los controles de los generadores (sistema de excitación y sistema de regulación carga - velocidad y turbina).

Un sistema eléctrico de potencia es un sistema dinámico con un alto grado de no linealidad, de manera que su respuesta ante la ocurrencia de una perturbación grande no puede determinarse mediante la linealización de las ecuaciones que describen su comportamiento. Tales ecuaciones deben resolverse iterativamente a partir de condiciones iniciales, mediante métodos numéricos para poder determinar con exactitud la respuesta del sistema. Sólo mediante este procedimiento puede hallarse la evolución en el tiempo de los ángulos de los rotores de las máquinas y por ende si permanecen en sincronismo. Adicionalmente, se puede hallar la evolución en el tiempo de otras magnitudes del sistema tales como tensiones, flujos, corrientes, etc.

El comportamiento de cada generador y demás elementos dinámicos puede ser modelado en el espacio de estados por medio de ecuaciones diferenciales:

$$p\mathbf{y} = \mathbf{f}(\mathbf{y}, \mathbf{z}) \quad (2.1)$$

En esta ecuación y en el resto del documento el símbolo p denota la derivada de una cantidad con respecto al tiempo; el vector y es el vector de estado y el vector z incluye otras variables del sistema (generalmente la tensión en terminales del elemento).

Sin embargo, hay una gran cantidad de generadores y elementos dinámicos distribuidos en todo el sistema e interconectados a través de la red de transporte, modelada por medio de ecuaciones algebraicas no lineales de la forma:

$$0 = g(y, z) \quad (2.2)$$

Los dos conjuntos de ecuaciones (diferenciales asociadas a los elementos dinámicos y algebraicas asociadas a la red) forman un sistema algebraico-diferencial de primer orden, este debe ser resuelto a partir de unas condiciones iniciales para obtener la respuesta en el tiempo del sistema. El análisis de gran perturbación es complejo desde el punto de vista computacional debido a los grandes sistemas de ecuaciones que deben ser resueltos utilizando pasos de tiempo pequeños para evitar errores y problemas de estabilidad numérica. El número de ecuaciones diferenciales (estados) utilizadas para describir la dinámica de cada generador puede ser de hasta varias decenas (generalmente se utiliza un mínimo de 2), dependiendo del modelo empleado para la máquina misma y sus controles. El acoplamiento de cada generador con la red se representa por medio de ecuaciones algebraicas que describen condiciones de frontera. La representación de la red por medio de ecuaciones algebraicas es posible debido a que se desprecia el efecto de los transitorios electromagnéticos (tanto en el sistema de transmisión como en el estator de las máquinas) cuya dinámica es más rápida que la de los transitorios electromecánicos de interés en estudios de estabilidad. Se supone que la red pasa de un estado estacionario a otro en una evolución cuasiestática. La validez de tales suposiciones se justifica con base en la comparación de los resultados obtenidos en las simulaciones con los monitoreados durante perturbaciones en sistemas reales. [Sierra, 2003; Sierra, 2007; Kundur, 1994]

2.2. Métodos de análisis para la simulación en el dominio del tiempo

Numerosos algoritmos han sido propuestos en la literatura para solucionar las ecuaciones asociadas al sistema, entre estos tenemos métodos basados en programación paralela, técnicas de relajación y otros. Estos algoritmos deben ser aplicados de tal forma que se aprovechen las características de las ecuaciones del sistema para mejorar la eficiencia computacional. Un aspecto importante es la velocidad con que se realicen las simulaciones, el impacto de las simulaciones en tiempo real o inclusive más rápidas sobre la operación del sistema es invaluable. La velocidad depende tanto del hardware como de la eficiencia del algoritmo empleado en la solución [Koester et al., 1992]. A continuación se describen dos métodos que han sido ampliamente utilizados [Kundur, 1994]. Las

ecuaciones del sistema son expresadas de la siguiente forma:

$$p\mathbf{x} = \mathbf{f}(\mathbf{x}, \mathbf{v}) \quad (2.3)$$

$$\mathbf{i}(\mathbf{x}, \mathbf{v}) = \mathbf{Y}\mathbf{v} \quad (2.4)$$

con unas condiciones iniciales $(\mathbf{x}_0, \mathbf{v}_0)$, donde

$\mathbf{x}$ = vector de estado del sistema

$\mathbf{v}$ = vector de componentes real e imaginaria de tensiones de barra del sistema

$\mathbf{i}$ = vector de componentes real e imaginaria de corrientes de barra del sistema

$\mathbf{Y}$ = matriz de la red del sistema, similar en estructura a la matriz admitancia de barras

2.2.1. Solución particionada con integración explícita

En este método las ecuaciones diferenciales y algebraicas se resuelven separadamente. Al inicio se tienen unas condiciones iniciales consistentes con el sistema de ecuaciones de tal forma que las derivadas de las variables de estado valen cero, $\mathbf{f}(\mathbf{x}, \mathbf{v}) = 0$, y el sistema está en un estado de equilibrio (estado estable). Al ocurrir una perturbación, el valor del vector $\mathbf{x}$ no puede cambiar repentinamente, las ecuaciones algebraicas se resuelven primero para hallar $\mathbf{v}$, $\mathbf{i}$ y otras variables de interés justo después de ocurrida la perturbación. Con este nuevo valor del vector $\mathbf{v}$ y el valor inicial de $\mathbf{x}$ se puede calcular el nuevo valor de $\mathbf{f}(\mathbf{x}, \mathbf{v})$ (vector de las derivadas de las variables de estado) y utilizarlo para hallar el valor del vector de estado en el primer paso de tiempo $\mathbf{x}_1$. A su vez este vector se utiliza para calcular los nuevos valores de tensiones $\mathbf{v}_1$ por medio de la solución de las ecuaciones algebraicas. A partir de estos últimos el proceso se repite hasta completar el tiempo de simulación. Cuando ocurre una perturbación sólo las variables de la red cambian instantáneamente, las variables de estado conservan su valor. Este método requiere el uso de técnicas para resolver sistemas de ecuaciones diferenciales y sistemas de ecuaciones algebraicas no lineales.

Los métodos de integración explícita tradicionalmente utilizados para resolver ecuaciones diferenciales son :

1. Método de Euler
2. Método de Euler Modificado
3. Métodos de Runge - Kutta de primer orden y de orden superior

Estos métodos son fáciles de implementar para la solución de sistemas de ecuaciones diferenciales complejos, sin embargo, tienen limitaciones de estabilidad numérica. Por lo tanto, el tamaño del paso de integración está limitado por las constantes de tiempo más pequeñas del sistema aún cuando los modos más rápidos se han amortiguado. Entre más detallados sean los modelos del sistema, el

problema es más crítico. Entre estos métodos, los más utilizados en programas de estabilidad por sus características son los métodos de Runge - Kutta de orden superior.

De otro lado, para resolver las ecuaciones no lineales de la red se utilizan métodos como:

1. Método de Gauss-Seidel
2. Método de Newton - Raphson

Un análisis detallado de estos métodos puede encontrarse en [Chapra y Canale, 1996]. Debido a que la solución de las ecuaciones diferenciales sólo requiere el uso de valores del instante de tiempo anterior, estas pueden ser particionadas de diferente forma, lo que permite la fácil implementación de técnicas para mejorar la eficiencia del algoritmo. El método de solución particionada con integración explícita ofrece ventajas tales como flexibilidad en la programación, simplicidad y robustez. Su principal desventaja es que puede presentar problemas de estabilidad numérica dependiendo de los auto-valores del sistema, lo que hace necesario utilizar pasos pequeños de tiempo durante todo el intervalo de simulación.

2.2.2. Solución simultánea con integración implícita

En este método las ecuaciones diferenciales y algebraicas se resuelven simultáneamente en cada paso de tiempo. Las ecuaciones diferenciales son convertidas a ecuaciones algebraicas utilizando un método de integración implícito. Según [Kundur, 1994], La base para estos métodos es la siguiente:

Si se tiene una ecuación diferencial de la forma:

$$px = f(x, t) \quad (2.5)$$

con $x = x_0$ para $t = t_0$. La solución para $t = t_1$ se puede hallar como:

$$x_1 = x_0 + \int_{t_0}^{t_1} f(x, \tau) d\tau \quad (2.6)$$

La integral puede ser evaluada utilizando funciones de interpolación que pasen por los puntos (x_0, t_0) y (x_1, t_1) . El método de integración implícito más sencillo utiliza interpolación lineal para hallar el valor de la integral, este método se conoce con el nombre de *regla trapezoidal*. La ecuación queda de la siguiente forma :

$$x_1 = x_0 + \frac{\Delta t}{2} [f(x_0, t_0) + f(x_1, t_1)] \quad (2.7)$$

Para el caso general :

$$x_{n+1} = x_n + \frac{\Delta t}{2} [f(x_n, t_n) + f(x_{n+1}, t_{n+1})] \quad (2.8)$$

En esta ecuación el valor de x en un instante está en función de su valor en ese instante y de su valor en el paso anterior, por lo tanto para conocer el nuevo valor debe resolverse una ecuación implícita.

La regla trapezoidal es un método que presenta buenas características desde el punto de vista de la estabilidad numérica. Si se emplean pasos de tiempo relativamente grandes, se afecta la exactitud de la solución (los modos más rápidos son filtrados) pero no su estabilidad. La regla trapezoidal es un método implícito de segundo orden, se han desarrollado métodos de orden superior, sin embargo su aplicación a las simulaciones en sistemas eléctricos de potencia no se ha popularizado debido a la dificultad en la programación y a que son más susceptibles a problemas de estabilidad.

Las ecuaciones dinámicas del sistema (conjunto de ecuaciones 2.3) son un conjunto de ecuaciones diferenciales de primer orden. Si $\mathbf{x}_n$ y $\mathbf{v}_n$ son los valores del vector de estado y del vector de tensiones en $t = t_n$, aplicando la regla trapezoidal para hallar $\mathbf{x}_{n+1}$:

$$\mathbf{x}_{n+1} = \mathbf{x}_n + \frac{\Delta t}{2} [\mathbf{f}(\mathbf{x}_{n+1}, \mathbf{v}_{n+1}) + \mathbf{f}(\mathbf{x}_n, \mathbf{v}_n)] \quad (2.9)$$

Para $t = t_{n+1}$ también deben satisfacerse las ecuaciones de red:

$$\mathbf{i}(\mathbf{x}_{n+1}, \mathbf{v}_{n+1}) = \mathbf{Y}\mathbf{v}_{n+1} \quad (2.10)$$

Si se definen los vectores $\mathbf{F}$ y $\mathbf{G}$ como:

$$\mathbf{F}(\mathbf{x}_{n+1}, \mathbf{v}_{n+1}) = \mathbf{x}_{n+1} - \mathbf{x}_n - \frac{\Delta t}{2} [\mathbf{f}(\mathbf{x}_{n+1}, \mathbf{v}_{n+1}) + \mathbf{f}(\mathbf{x}_n, \mathbf{v}_n)] \quad (2.11)$$

$$\mathbf{G}(\mathbf{x}_{n+1}, \mathbf{v}_{n+1}) = \mathbf{Y}\mathbf{v}_{n+1} - \mathbf{i}(\mathbf{x}_{n+1}, \mathbf{v}_{n+1}) \quad (2.12)$$

los valores desconocidos $\mathbf{x}_{n+1}$ y $\mathbf{v}_{n+1}$ deben satisfacer la condición:

$$\mathbf{F}(\mathbf{x}_{n+1}, \mathbf{v}_{n+1}) = 0 \quad (2.13)$$

$$\mathbf{G}(\mathbf{x}_{n+1}, \mathbf{v}_{n+1}) = 0 \quad (2.14)$$

Las ecuaciones (2.13) y (2.14) son ecuaciones algebraicas no lineales. Estas ecuaciones son muy dispersas, característica que puede ser aprovechada para mejorar la eficiencia del algoritmo utilizado. Aplicando el método de Newton para solucionar estas ecuaciones:

$$\begin{bmatrix} \mathbf{x}_{n+1}^{k+1} \\ \mathbf{v}_{n+1}^{k+1} \end{bmatrix} = \begin{bmatrix} \mathbf{x}_{n+1}^k \\ \mathbf{v}_{n+1}^k \end{bmatrix} + \begin{bmatrix} \Delta \mathbf{x}_{n+1}^k \\ \Delta \mathbf{v}_{n+1}^k \end{bmatrix} \quad (2.15)$$

Los valores de $\Delta \mathbf{x}_{n+1}^k$ y $\Delta \mathbf{v}_{n+1}^k$ son hallados a partir de:

$$\begin{bmatrix} -\mathbf{F}(\mathbf{x}_{n+1}^k, \mathbf{v}_{n+1}^k) \\ -\mathbf{G}(\mathbf{x}_{n+1}^k, \mathbf{v}_{n+1}^k) \end{bmatrix} = \begin{bmatrix} \frac{\partial \mathbf{F}}{\partial \mathbf{x}} & \frac{\partial \mathbf{F}}{\partial \mathbf{v}} \\ \frac{\partial \mathbf{G}}{\partial \mathbf{x}} & \frac{\partial \mathbf{G}}{\partial \mathbf{v}} \end{bmatrix} \begin{bmatrix} \Delta \mathbf{x}_{n+1}^k \\ \Delta \mathbf{v}_{n+1}^k \end{bmatrix} \quad (2.16)$$

Los valores del jacobiano $\mathbf{J}$ en la ecuación anterior se hallan para $\mathbf{x}_{n+1}^k$ y $\mathbf{v}_{n+1}^k$, y este tiene la siguiente estructura:

$$\mathbf{J} = \begin{bmatrix} \frac{\partial \mathbf{F}}{\partial \mathbf{x}} & \frac{\partial \mathbf{F}}{\partial \mathbf{v}} \\ \frac{\partial \mathbf{G}}{\partial \mathbf{x}} & \frac{\partial \mathbf{G}}{\partial \mathbf{v}} \end{bmatrix} = \begin{bmatrix} \mathbf{A}_D & \mathbf{B}_D \\ \mathbf{C}_D & (\mathbf{Y} + \mathbf{Y}_D) \end{bmatrix} \quad (2.17)$$

Las matrices $\mathbf{A}_D$, $\mathbf{B}_D$, $\mathbf{C}_D$ y $\mathbf{Y}_D$ dependen de los modelos de los elementos dinámicos del sistema y las cargas estáticas no lineales.

Las ecuaciones 2.13 y 2.14 pueden expresarse en términos de las matrices como:

$$\mathbf{A}_D \Delta \mathbf{x}_{n+1}^k + \mathbf{B}_D \Delta \mathbf{v}_{n+1}^k = -\mathbf{F}(\mathbf{x}_{n+1}^k, \mathbf{v}_{n+1}^k) \quad (2.18)$$

$$\mathbf{C}_D \Delta \mathbf{x}_{n+1}^k + (\mathbf{Y} + \mathbf{Y}_D) \Delta \mathbf{v}_{n+1}^k = -\mathbf{G}(\mathbf{x}_{n+1}^k, \mathbf{v}_{n+1}^k) \quad (2.19)$$

A partir de estas ecuaciones es posible hallar $\Delta \mathbf{x}_{n+1}^k$ y $\Delta \mathbf{v}_{n+1}^k$ a partir de:

$$\Delta \mathbf{x}_{n+1}^k = -\mathbf{A}_D^{-1} [\mathbf{F}_{n+1}^k + \mathbf{B}_D \Delta \mathbf{v}_{n+1}^k] \quad (2.20)$$

$$(\mathbf{Y} + \mathbf{Y}_D - \mathbf{C}_D \mathbf{A}_D^{-1} \mathbf{B}_D) \Delta \mathbf{v}_{n+1}^k = -\mathbf{G}_{n+1}^k + \mathbf{C}_D \mathbf{A}_D^{-1} \mathbf{F}_{n+1}^k \quad (2.21)$$

Finalmente teniendo estos valores se hallan $\mathbf{x}_{n+1}^{k+1}$ y $\mathbf{v}_{n+1}^{k+1}$ a partir de la ecuación 2.15. Hay que tener en cuenta que el procedimiento anterior es válido cuando las funciones $\mathbf{F}$ y $\mathbf{G}$ son diferenciables. Cuando ocurre una discontinuidad tal como una falla u operación de interruptores, solamente se resuelven las ecuaciones de red para corregir los valores del vector $\mathbf{v}$ en el instante en que ocurre la perturbación, el vector de estado $\mathbf{x}$ no se cambia. Luego se continúa con el proceso de integración implícita.

2.3. Redes neuronales Artificiales - Perceptrón multicapa

En esta sección se presentan brevemente algunos de los aspectos más relevantes de las redes neuronales artificiales (ANN, Artificial neural networks), utilizados para el desarrollo de la investigación aquí presentada. Una información más completa sobre ANN puede ser encontrada en [S. Rusell, 2002; Looney, 1996; Haykin, 1994].

2.3.1. Aspectos Básicos

Las ANN son caracterizadas por su arquitectura, algoritmos de entrenamiento o aprendizaje y funciones de activación. La arquitectura describe básicamente las conexiones entre las neuronas y consiste de una capa de entrada, una capa de salida y generalmente, una o varias capas ocultas entre éstas. En la figura 2.1 se muestra una de las redes comúnmente usadas, llamada, la red neural artificial de propagación hacia adelante (feed-forward ANN), con una capa oculta. Las capas en esta red son interconectadas por enlaces de comunicación que son asociados con pesos, los cuales establecen los efectos en la información que pasa a través de ellos. Estos pesos son determinados por el algoritmo de entrenamiento [Aranguren y Muzachiodi, 2003].




Figura 2.1: Red Neuronal típica con una capa oculta

Dependiendo del algoritmo de entrenamiento las ANN pueden ser categorizadas en: a) Redes de pesos fijos, las cuales no necesitan ningún tipo de entrenamiento; b) Redes no supervisadas, que se entrenan para un ajuste de pesos en las conexiones a partir de sólo los datos de entrada; c) Redes supervisadas que son las más comúnmente empleadas y que utilizan en el entrenamiento los datos de entrada y salida para actualizar los pesos y umbrales (bias). El perceptrón multicapa (MLP, Multi-Layer Perceptron) está dentro de esta última categoría.

La función de activación relaciona la salida de una neurona ante sus entradas, a partir del nivel de actividad de cada una de las entradas de la neurona. Algunas de las funciones comúnmente utilizadas son: escalón (umbral), lineal mixta, identidad, sigmoideal y tangente hiperbólica [Haykin, 1994]. El proceso de aprendizaje de la red perceptrón multicapa involucra el empleo de los datos de entrada y salida para determinar los pesos y umbrales. Una de las técnicas utilizadas para obtener estos parámetros es el algoritmo “back-propagation” [Haykin, 1994; Aranguren y Muzachiodi, 2003]. En este método, los pesos y umbrales son ajustados iterativamente para lograr un mínimo

error cuadrático medio entre la salida de la red y el valor deseado, tal como se presenta en la sección de pruebas y resultados.

2.3.2. Estrategia básica de ajuste del MLP

El perceptrón multicapa es la red neuronal más comúnmente utilizada en aplicaciones tales como reconocimiento de patrones, control, clasificación, entre las más importantes [yuen Chow y Thomas, 1989]. Los pasos seguidos por la estrategia básica de ajuste, en la mayoría de aplicaciones reportadas y aplicado en esta investigación se presentan a continuación:

2.3.2.1. Selección de las entradas y extracción de las características

Este es el primer paso para cualquier problema de reconocimiento de patrones y consiste básicamente en la determinación de cuales de las variables disponibles (posibles entradas), tienen alguna relación con lo que se desea identificar (clase como salida). Este paso es importante ya que define tanto el desempeño como el tamaño de la ANN.

2.3.2.2. Definición de los datos de entrenamiento

La definición del conjunto de datos de entrenamiento es importante, ya que éstos deben contener información sobre todas las salidas posibles que se desean identificar. Los datos de entrenamiento ayudan a determinar los parámetros de la red.

2.3.2.3. Selección de la ANN

En este paso se define el tamaño y arquitectura de la red (número de neuronas, entradas, capas ocultas, neuronas ocultas, etc.). Este paso se puede realizar antes de iniciar el ajuste de la red, aunque recientemente hay otras metodologías propuestas que permiten variaciones en la arquitectura en función de un mejor desempeño [Mora y Pérez, 2006].

2.3.2.4. Entrenamiento de la ANN

En este proceso, a partir de la presentación de datos de entrada (variables) y de datos de salida (clases a reconocer), tomados del conjunto de entrenamiento, se establece una relación entre entradas y salidas. Esta relación es del tipo “caja negra”, es decir que ésta no se puede presentar de manera explícita, lo que constituye una de las desventajas de las redes neuronales. En el entrenamiento, comúnmente los pesos y umbrales de la red son actualizados solamente después de que la totalidad del conjunto de datos ha sido aplicado a la red.

2.3.2.5. Prueba

Utilizando datos diferentes a los utilizados en el entrenamiento, se puede obtener un índice de confianza en la red neuronal. Uno de los índices más utilizados es el que se presenta en la ecuación (2.22), y está dado para el caso en el cual la salida puede tomar muchos valores o clases y es de carácter discreta.

$$confianza = \frac{\frac{Datosde\ prueba - Datosbien\ clasificados}{datosde\ prueba}}{(2.22)}$$

Para el caso donde hay una sola salida, se utiliza como índice de medición el error medio cuadrático entre la salida deseada y la obtenida. Este índice es el que se utiliza en esta aplicación, tal como se presenta en la ecuación (2.23)

$$E_{error\ medio\ cuadrático} = \sqrt{\sum_{i=1}^N \frac{(Di_{Real} - Di_{Estimado})^2}{N}} \quad (2.23)$$

Donde N es el número total de muestras comparadas, y Di corresponde al dato i-esimo real y estimado por la ANN en el proceso de prueba, respectivamente.

Capítulo 3

Redes Neuronales aplicadas al modelado de la máquina síncrona

El presente capítulo tiene como fin revisar una recopilación de los trabajos mas relevantes en el área de identificación del modelo de la máquina síncrona basado en técnicas de inteligencia artificial, en especial redes neuronales. Se distinguen dos categorías según se apliquen la redes neuronales, la primera para estimación de los parámetros del modelo matemático de la máquina y la segunda para reemplazar el modelo matemático de la máquina por un modelo del tipo caja negra basado en técnicas heurísticas. Este capítulo se centra en la segunda categoría por ser una alternativa más atractiva para aplicaciones en tiempo real. Se destacan las redes tipo perceptrón multicapa (MLP, Multilayer Perceptron) y redes de función de base radial (RBF, Radial Basis Function) para la identificación en línea de la dinámica de la máquina síncrona. Sus características ofrecen una rápida convergencia y alta adaptación ante los cambiantes sistemas de potencia en busca de aplicaciones en tiempo real.

3.1. Modelado de la máquina síncrona

Las máquinas síncronas son ampliamente utilizadas en el sector industrial y juegan un papel muy importante en la estabilidad de los sistemas de potencia. Un apropiado modelo para la máquina síncrona es esencial para un análisis valido de estabilidad y funcionamiento dinámico del sistema. Casi ocho décadas después de la primera publicación en esta área [Kilgore, 1931; Wright, 1931], el tema aun sigue siendo una atractiva y desafiante materia de investigación.

Muchos modelos de la máquina síncrona han sido desarrollados a través de los años empleando diversas aproximaciones y enfoques para soslayar principalmente la sobrecarga computacional asociada a la compleja dinámica y no linealidad inherentes a la representación a gran escala. Probablemente el modelo más simple disponible de la máquina síncrona usado para estudios de estabilidad[Grainger y Stevenson, 1995; Kundur, 1994], es el que describe una sola máquina síncrona

conectada a una barra infinita, basado en la ecuación de oscilación, usando el ángulo de oscilación y la velocidad del rotor como variables de estado. Un modelo de descomposición de flujo, el cual incluye una o más variables de estado, adicionalmente a las variables de estado usadas en la ecuación de oscilación, fue ampliamente usado por [DeMarco y Qian, 1986]. Sin embargo, cuando es necesario un incremento en la complejidad de la representación, comúnmente es utilizado un modelo de cinco o siete variables de estado para una máquina síncrona trifásica. [Fitzgerald et al., 1990]

Modelos simples de la máquina son buenos para propósitos de análisis académico pero no lo suficientemente exactos para predecir el desempeño de la máquina en aplicaciones reales para propósitos de control y evaluación de estabilidad en sistemas de potencia. En tales situaciones, las no linealidades en la máquina, a causa de los efectos de saturación y flujo ligado, deben ser adheridos al modelo de la máquina [Anderson y Fouad, 1997; Kundur, 1994]. Estudios más completos sobre las propiedades de la máquina síncrona, los cuales detallan el modelo de los excitadores, proporcionan modelos más completos y complicados que están siendo cada vez más desarrollados para proveer una representación cada vez más exacta. Desafortunadamente, a medida que la complejidad en los modelos aumenta, estos se hacen inapropiados para aplicaciones en línea y en tiempo real.[yuen Chow y Thomas, 1989]

En un sistema de potencia una máquina síncrona es un dispositivo no lineal de acción rápida de múltiples entradas y múltiples salidas. Dado su amplio rango de operación, dinámica compleja, no-linealidad y la configuración cambiante del sistema, la simulación para el análisis del sistema y evaluación de la estabilidad requiere un modelo muy exacto y por ende exige un alto costo computacional. La idea de las redes neuronales originada en la década de los cuarenta, ha sido ampliamente empleada en aplicaciones del sector eléctrico y mas específicamente en el modelado de la máquina síncrona demostrando que son una alternativa viable para la solución del problema en cuanto a exigencia computacional como también complejidad del modelo [yuen Chow y Thomas, 1989; Teeuwsen et al., 2004]. Las propiedades fundamentales de las redes neuronales deben ser cuidadosamente examinadas para determinar: a) Si el modelo de la red neural puede ser entrenado en base a medidas disponibles de la máquina en ejecución para diferentes condiciones de operación, b) cuales deben ser los patrones de entrenamiento para el modelo de representación de la máquina síncrona, c) la adaptación del modelo basado en redes neuronales a los modelos matemáticos existentes y bien desarrollados del generador síncrono para propósitos de evaluación de desempeño y valoración de la estabilidad dinámica, y d) el modelo basado en redes neuronales debe poder generalizar a partir de los casos de entrenamiento y responder con exactitud para los casos que no han sido entrenados [Tsai y Keyhani, 1995]. Sin embargo, existen una gran cantidad de publicaciones respecto al empleo de redes neuronales en el proceso de modelamiento de la máquina síncrona y recientemente la aplicación de estas ha incrementado considerablemente. Adicionalmente, la utilización de redes neuronales requiere la determinación de parámetros propios y arquitecturas definidas que a través del tiempo han sido propuestas y probadas en el modelamiento de la máquina [Park et al., 2002; Park et al., 2005]. Por lo tanto, se hace necesaria una recopilación

bibliográfica respecto al empleo de la redes neuronales en el modelamiento de la máquina síncrona la cual sirva como guía para todo aquel que desee emplear esta técnica de inteligencia artificial u afines en el proceso de la representación de la máquina síncrona para propósitos de evaluación de estabilidad y análisis de sistemas de potencia.

3.2. Métodos Tradicionales

El modelo de Park, un modelo ampliamente utilizado y bien documentado, transforma el estado de la máquina trifásica balanceada a un marco de referencia rotante (marco de Park) [Kundur, 1994]. Este modelo es la base de la mayoría de los métodos tradicionales desarrollados para el modelamiento de la máquina síncrona. Los métodos tradicionales de modelado de la máquina síncrona están bien especificados en el estándar IEEE 115 [1995, 1995]. Estos métodos asumen una estructura conocida para la máquina síncrona, usando teorías establecidas adecuadamente como la transformación de Park. Estas dirigen el problema a encontrar los parámetros de la estructura conocida. Usualmente los procedimientos envuelven dificultad y pruebas que consumen gran cantidad de tiempo. Estas aproximaciones incluyen la prueba de corto circuito, las pruebas de respuesta en frecuencia con rotor parado (SSFR) y respuesta en frecuencia de circuito abierto (OCFR). Estas pruebas deben ser llevadas a cabo principalmente cuando la máquina esta fuera de servicio.[Molenaar et al., 2002; Ravan et al.,]

Para vencer los defectos en los métodos tradicionales, métodos de identificación basados en medidas en línea han ganado atención durante los últimos años [Chen et al., 1990; Pilluta y Keyhani, 1999; H. Bora Karayaka y Selin, 2001; Park et al., 2002; Ravan et al., ; Teeuwsen et al., 2004; Boozari, 2004; Park et al., 2005; Wei-Feng y Shi-Long, 2005; Wang et al., 2006; Ye et al., 2006; Angel et al., 2007b; Angel et al., 2007a]. Estos métodos pueden ser divididos en dos categorías. En la primera categoría (sección 3.3), los parámetros físicos de la máquina son estimados a partir de medidas en línea, asumiendo una estructura conocida para la máquina síncrona (igual que los métodos tradicionales). La segunda categoría (sección 3.4), trata de modelar el generador síncrono como una caja negra usando datos de entrada y salida. En los modelos del tipo caja negra la estructura del modelo se asume como desconocida desde el principio. Sólo es importante la relación del conjunto de datos de entrada con el conjunto de datos de salida.

3.3. Estimación de parámetros de la máquina síncrona

La estimación de parámetros de la máquina síncrona tiene múltiples aplicaciones. Básicamente el empleo de redes neuronales en esta área tiene como fin adherir complejidad y exactitud al modelo de la máquina síncrona sin abandonar la representación matemática con una estructura definida. En la figura 3.1 se presenta un esquema del proceso de estimación de parámetros de la máquina




Figura 3.1: Estimación de parámetros de la máquina síncrona.

síncrona empleando redes neuronales artificiales. En [Tsai y Keyhani, 1995] se presenta un modelo del generador síncrono de polos salientes que tiene en cuenta los efectos de saturación, utilizando un modelo basado en redes neuronales del tipo feed-forward, que incluye diversas condiciones de carga de la máquina, diferentes niveles de excitación y ángulos del rotor. Se estudia la característica no lineal de una máquina síncrona trifásica de polos salientes y valores nominales de 5KVA y 240 V, entrenando la red neuronal artificial (ANN) con datos de respuesta a pequeñas perturbaciones y el algoritmo de estimación de máxima probabilidad. El algoritmo Back-propagation es utilizado como algoritmo de aprendizaje. Como resultado [Tsai y Keyhani, 1995] obtiene que el modelo desarrollado con la red neuronal brinda la posibilidad de ser empleado para estudios de estabilidad transitoria requiriendo pequeñas modificaciones computacionales en la representación del modelo de saturación.

De manera similar [Pilluta y Keyhani, 1999] emplea redes neuronales para estimación de parámetros de un generador síncrono de rotor cilíndrico. Se consideran los efectos debidos al nivel de excitación, ángulo del rotor y potencia real generada. El entrenamiento de la red también se hace con datos reales de la máquina para pequeñas perturbaciones, sin embargo a diferencia de [Tsai y Keyhani, 1995] el modelo es validado con otros datos y grandes perturbaciones. Las propuestas presentadas en [Tsai y Keyhani, 1995; Pilluta y Keyhani, 1999] usan las redes neuronales para estimar el efecto de la saturación de la máquina reflejado en las inductancias L_{ads} y L_{aqs} . Por tanto, no se abandona el modelo matemático solo se modifica la manera en que se hallan las reluctancias para cada paso de tiempo en la simulación. Se resalta el uso de las componentes de eje directo y cuadratura de la tensión y corriente en terminales y la corriente de excitación como patrones de entrada a la red neuronal.

Por otro lado, una propuesta para la estimación de los principales parámetros del rotor de un generador síncrono de una gran turbina a vapor basada en redes neuronales es presentada en [H. Bora Karayaka y Selin, 2001]. Se emplean datos reales para el entrenamiento que corresponden con diferentes condiciones de carga y niveles de excitación. Como entrada se utilizan la media

y desviación estándar del ángulo de potencia y la corriente de excitación. El desempeño de la estimación de parámetros es validado con simulación exhaustiva en el tiempo y comparación con los valores de fábrica del generador. Se demuestra que los modelos basados en redes neuronales interpolan correctamente entre los patrones no usados durante el entrenamiento.

3.4. Representación de la dinámica de la máquina síncrona: modelo de caja negra

Como primera aproximación al modelo de caja negra de la máquina síncrona en [yuen Chow y Thomas, 1989] se emplea una red multicapa para representar el modelo no lineal de una máquina síncrona. Esta propuesta utiliza el vector de control de la representación del espacio de estados (U_k) y el vector de salida (Y_k) para predecir el vector de estados siguiente (X_{k+1}). Se presentan resultados para el caso más sencillo, un generador síncrono conectado a una barra infinita sin considerar los efectos de saturación y suponiendo el sistema balanceado. En [yuen Chow y Thomas, 1989] presentan resultados para 10 y 20 neuronas en la capa oculta con lo cual concluye que el modelo desarrollado se aproxima y puede ser mejorado al determinarse un número de neuronas óptimo.

Uno de los principales problemas a la hora de determinar un modelo de la máquina síncrona basado en la relación de entradas y salidas es la determinación del conjunto de señales de entrada consideradas para la obtención resultados satisfactorios en la predicción de salida. En relación al conjunto de entrada de datos, el uso de la teoría de los conjuntos aproximados (RST, Rough Set Theory) es estudiada en [Wang et al., 2006] para determinar el conjunto mínimo de patrones útiles de entrada a una red neuronal de función de base radial (RBF, Radial Función Basis), esta propuesta es utilizada para modelar el comportamiento dinámico no lineal de un generador síncrono de una embarcación a partir de datos reales. Como resultado el modelo basado en la metodología que combina RST y RBF posee gran exactitud y una alta capacidad de generalización.

En el estudio del modelado de la dinámica de la máquina síncrona muchas arquitecturas de redes neuronales han sido empleadas, mas aún, algunas arquitecturas han sido propuestas para aplicaciones específicas derivadas de la investigación en este campo. Un nuevo tipo de red neuronal fue propuesto por [Wei-Feng y Shi-Long, 2005] y aplicado en el modelamiento de un generador síncrono de la marina para la simulación en tiempo real. La red usa un algoritmo back-propagation para la adaptación de los pesos de la red. Las entradas utilizadas para la red son la potencia del torque mecánico y la corriente de excitación, las salidas: la frecuencia y la tensión en terminales del generador. [Wei-Feng y Shi-Long, 2005] prueba que los datos obtenidos con la red propuesta son muy cercanos a los datos del simulador de la marina (Error Medio Cuadrático MSE mucho menor que 10^{-3}) y además comparada con otras redes (MLP, Multilayer perceptron), el numero de neuronas en la capa oculta es menor obteniendo una buena generalización.

Modelos de identificación global en línea del ge-nerador síncrono son ampliamente desarro-




Figura 3.2: Esquema empleado en [Park et al., 2002] para la identificación en línea de la dinámica no lineal del generador síncrono

llados y analizados. [Park et al., 2002] compara el desempeño de una red tipo MLP (Multilayer Perceptron) frente a una RBF (Radial Function Basis), para la identificación en línea de la dinámica no lineal de un generador síncrono. Se emplea la variación de las señales a partir de los valores de estado estable. Se investigan las implicaciones en la complejidad computacional para el procesamiento de los datos en el entrenamiento en línea, la generalización y la convergencia global para simulaciones en el tiempo. En la figura 3.2 se presenta el esquema empleado por [Park et al., 2002] en la comparación de las redes tipo MLP y RBF. Los resultados de las simulaciones muestran que comparada al MLP, la RBF es más simple de implementar, necesita menos memoria de computo, converge más rápido, y logra la convergencia global aun cuando las condiciones de operación cambian. Sin embargo, años más tarde los mismos autores publican de nuevo en [Park et al., 2005], la comparación de los modelos basados en MLP y RBF para la representación de la dinámica del generador síncrono solo que esta vez el generador es analizado como parte de un sistema de potencia y el modelo de excitación de la máquina y la turbina son considerados. El estudio también se basa en simulaciones en el dominio del tiempo para evaluar los requerimientos computacionales en el procesamiento de los datos durante el entrenamiento en línea, la convergencia local y global en línea. A diferencia de [Park et al., 2002] en [Park et al., 2005] se usan señales y variaciones de las mismas, correspondientes a la potencia mecánica, la corriente de excitación, la frecuencia y la tensión de la máquina, como entradas del identificador, y se predice la variación en la velocidad y la tensión en terminales del generador. De [Park et al., 2005] se concluye que ambos identificadores se comportan bien. Sin embargo, pese a que las RBF presentan mejores características de desempeño, si solo se usan variaciones de la señales como entradas del identificador, la red MLP

es recomendada, pues la RBF requiere cálculos extra como por ejemplo hallar las funciones centrales. Adicionalmente para la implementación hardware en tiempo real, el identificador MLP es preferido, pues los esfuerzos para determinar los centros de la RBF pueden ser evitados.

La representación de la máquina síncrona comúnmente tiene como finalidad el estudio de la estabilidad en los sistemas de potencia. Aplicaciones a la valoración de la estabilidad ante perturbaciones de pequeña señal son propuestas en [Teeuwsen et al., 2004; Dong, 1998; Vittal et al., 2005]. Específicamente en [Teeuwsen et al., 2004], se propone un método para la predicción de los modos críticos (Eigenvalores) empleados en la valoración de estabilidad de sistemas de potencia basado en redes neuronales. Esta publicación se enfoca especialmente en las oscilaciones presentes entre áreas de grandes sistemas interconectados. Se reduce el número de variables de estado para la predicción de los eigenvalores y así obtener la condición de estabilidad del sistema con gran exactitud (menor al 3.5 % para el peor caso). Sin embargo, los estudios de estabilidad a pequeña señal no son de gran reto. La complejidad numérica presente en el estudio de estabilidad ante grandes perturbaciones tiene especial interés. El modelo no lineal de la máquina junto con la interconexión de un gran número de generadores en un sistema de potencia representa un verdadero reto y es el punto de mayor interés para utilizar modelos basados en métodos heurísticos y especialmente redes neuronales.

Las aplicaciones de las redes neuronales al estudio de estabilidad transitoria de ángulo ante grandes perturbaciones han incrementado en los últimos años [Koester et al., 1992; Pavella et al., 2000; Boozari, 2004; Morales et al., 2006; Ye et al., 2006; Angel et al., 2007a; Angel et al., 2007b]. [Angel et al., 2007a] propone utilizar redes neuronales para determinar el ángulo del rotor para estudios de estabilidad transitoria de ángulo. La novedad de este aporte reside en el empleo de medidas fasoriales de tensión y corrientes tomadas en el lado de alta del sistema de potencia, como entradas de la red neuronal. Se demuestra que la estimación directa del ángulo no produce resultados satisfactorios y se propone la implementación de dos redes neuronales para determinar el seno y el coseno del ángulo, lo cual produce buenos resultados. La red MLP es entrenada fuera de línea basada en datos de simulación y es puesta a prueba en aplicaciones en tiempo real en la predicción y control de inestabilidad transitoria. De igual forma, [Angel et al., 2007b] presenta una metodología basada en redes neuronales para la estimación del ángulo y la velocidad del rotor aplicable a estudios de estabilidad transitoria y control en tiempo real. Como aporte se considera el uso de dos redes neuronales para tal fin, una red estima el ángulo del rotor y la otra, utilizando adicionalmente el valor predicho del ángulo del rotor estima la velocidad de la máquina. Se presentan resultados para un sistema de una máquina conectada a una barra infinita utilizando el método planteado y comparandolo con los resultados al emplear el modelo clásico de la máquina síncrona.

Debido a que el empleo de las redes neuronales en la representación del modelo de la máquina síncrona tiende a ser predictivo, en [Boozari, 2004] es estudiada la manera de utilizar técnicas de predicción y filtrado de estados para construir una red neuronal de retardo (TDNN, Time Delay Neural Network) y una red de interrelación funcional (FLN, Functional Link Network) para cap-

turar la dinámica del sistema de potencia. Adicionalmente se desarrolla una herramienta basada en redes neuronales para determinar la estabilidad e inestabilidad del sistema luego del despeje de una falla. El método híbrido empleando redes neuronales (TDNN y FLN) es puesto en practica para evaluar exitosamente la función de energía transitoria (TEF, Transient Energy Function) como indicador de seguridad.

3.5. Otras técnicas de inteligencia artificial empleadas en el mo-delado de la máquina síncrona

Es común encontrar en la literatura aplicaciones de la redes neuronales para el modelamiento de la máquina síncrona y la dinámica del sistema de potencia. Sin embargo esta técnica heurística no es la única. El empleo de otras técnicas de inteligencia artificial en aplicaciones del sector eléctrico, tales como la técnica de los K-vecinos mas cercanos (K-NN, K-Nearest Neighbor) [Barrera et al., 2007a] y las máquinas de soporte vectorial (SVM, support machine vector) [Morales y Gómez, 2005; Morales et al., 2007b] entre otras [Morales et al., 2009; Mora, 2006], muestran que las redes neuronales no son la única solución, sin embargo son una gran alternativa.

En la determinación de la dinámica de la máquina síncrona empleada para estudios de estabilidad se resalta la propuesta presentada en [Ye et al., 2006], la cual consiste en aplicar la SVM para determinar la estabilidad transitoria de un sistema de potencia ante el evento de una falla en las lineas de transmisión. Estrictamente se emplea una estrategia de clasificación basada en SVM para determinar si el sistema es estable o inestable (2 clases). Las entradas del clasificador consisten de atributos tomados de una sola máquina del sistema de potencia, con el fin de disminuir la dimensionalidad del espacio de entrada. Se realizan pruebas con el sistema de prueba de la IEEE de 50 generadores y se muestra que los atributos tomados de una máquina con coeficiente de inercia pequeño son efectivos para la evaluación de la estabilidad en sistemas de potencia, empleando SVM y kernel RBF.

A la búsqueda de la identificación de un modelo de tipo caja negra para la máquina síncrona se suma la propuesta presentada en [Ravan et al.,]. Esta publicación explora la manera de utilizar redes wavelet para identificar la dinámica del generador síncrono basado en el éxito de las redes wavelet para el modelado de sistemas dinámicos no lineales [Liu et al., 1998]. El método propuesto es aplicado sobre un modelo no lineal de séptimo orden de la máquina síncrona con efectos de saturación. En este estudio la tensión de campo es considerada como la entrada y la potencia activa de salida y la tensión en terminales de la máquina se consideran las salidas del generador síncrono. Los resultados muestran una buena aproximación del modelo identificado, aun ante condiciones diferentes de operación.

Capítulo 4

Modelo neuronal de la máquina síncrona para estudios de estabilidad

En este capítulo, se presenta la metodología propuesta para la obtención de una red neuronal del tipo perceptrón multicapa que reproduzca la dinámica de la máquina síncrona y su aplicación al estudio de estabilidad de ángulo ante gran perturbación en sistemas eléctricos de potencia.

4.1. Modelo neuronal clásico de la máquina síncrona

En esta sección se presenta la utilización de redes neuronales del tipo perceptrón multicapa (MLP) en la estimación de las principales variables que representan el modelo clásico de la máquina síncrona mediante la aplicación de un modelo tipo caja negra, desarrollado a partir de medidas de tensión y corriente en terminales de la misma.

Los registros obtenidos de simulaciones en el dominio del tiempo realizados sobre un sistema de potencia básico (generador conectado a un barraje infinito), son utilizados para crear la base de datos de entrenamiento y posteriormente validar la metodología basada en redes neuronales artificiales propuesta para la reproducción de la dinámica de la máquina síncrona.

4.1.1. Modelo clásico de la máquina síncrona

En el caso de estudios en los cuales el periodo de análisis es pequeño en comparación con la constante de tiempo transitoria de circuito abierto, el modelo de la máquina síncrona es frecuentemente simplificado asumiendo E' constante, a través de todo el periodo de estudio. Otra aproximación común, simplifica el modelo de la máquina significativamente al ignorar el efecto transitorio de los polos salientes asumiendo $X'd = X'q = X'$, y también considera que el flujo ligado al circuito de amortiguamiento permanece constante (asociado con el eje q del circuito del rotor correspondiente con $X'q$). La representación clásica de la máquina síncrona en estudios de estabilidad es entonces, como se muestra en [Kundur, 1994], una fuente de tensión de magnitud

constante detrás de la impedancia transitoria ($R_a + j X'$), el ángulo de la fuente se varía durante la simulación para representar el deslizamiento de los polos. El modelo se ilustra en la figura 4.1, el hecho de suponer que las reactancias transitorias de eje directo y eje en cuadratura son iguales es más crítico para máquinas de polos salientes, ya que el período transitorio en el eje en cuadratura no está claramente definido para la mayoría de estas máquinas. Por tanto, la parte eléctrica de la máquina síncrona queda descrita por la ecuación:

$$E' = E_t + (R_a + j \cdot X') \cdot I_t \quad (4.1)$$




Figura 4.1: Modelo clásico de la máquina síncrona

Considerando que los encadenamientos de flujo de los circuitos del rotor que tienen incidencia en el periodo transitorio permanecen constantes, el fasor correspondiente a la tensión detrás de la reactancia transitoria permanece fijo respecto a los ejes directo y en cuadratura de la máquina. Esto permite tomar el ángulo de este fasor como medida del ángulo del rotor. La representación clásica de la máquina síncrona en estudios de estabilidad considera dos variables de estado: ángulo del rotor y desviación en la velocidad del rotor. Entonces, para el modelo clásico, las dos ecuaciones que representan la dinámica de cada máquina son:

$$\frac{d\Delta\omega}{dt} = \frac{1}{2H}(T_m - T_e - K_D\Delta\omega) \quad (4.2)$$

$$\frac{d\delta}{dt} = \omega_o\Delta\omega \quad (4.3)$$

donde

$\Delta\omega$ = desviación de velocidad rotórica, pu

δ = ángulo del rotor, radianes eléctricos

H = constante de inercia de la máquina, s

T_m = par mecánico, pu

T_e = par eléctrico, pu

ω_o = velocidad angular nominal, radianes eléctricos/s

K_D = Coeficiente de torque amortiguante, pu.

Estas dos ecuaciones 4.2 y 4.3, junto con la representación de fuente de tensión detrás de la impedancia transitoria (4.1), constituyen el modelo clásico de la máquina síncrona en estudios de estabilidad. El valor inicial del ángulo del rotor para cada máquina es el valor del ángulo de la tensión detrás de la reactancia transitoria, que puede ser calculado a partir de los datos del flujo de cargas que representan la condición inicial de equilibrio. Es importante resaltar que el modelo clásico desprecia los transitorios del estator de la máquina así como la dinámica de los circuitos del rotor. La primera simplificación que inclusive se adopta en modelos más detallados de la máquina es necesaria para estudios en sistemas de gran dimensión y ha sido justificada satisfactoriamente, de otro lado la segunda simplificación constituye la limitante principal del modelo clásico.

4.1.2. Desarrollo del modelo neuronal clásico

El propósito de la ANN (Artificial Neural Network) planteada consiste en predecir el ángulo del rotor de la máquina síncrona para un instante t , empleando la tensión y corriente en terminales de la máquina en instantes previos. A continuación se presentan los aspectos más importantes para el ajuste de la red neuronal.

Como entradas de la red neuronal se seleccionaron la componente real e imaginaria de la tensión y la corriente en los terminales de la máquina en los instantes $(t-1)$, $(t-2)$ y $(t-3)$. La salida del modelo basado en la red neuronal consiste en una neurona que representan el ángulo del rotor para un punto de operación específico, tal como se expresa en 4.4

$$[\delta(t)] = f \left\{ \begin{array}{l} E_{tR}(t-i \cdot \Delta t), E_{tI}(t-i \cdot \Delta t), \\ I_{tR}(t-i \cdot \Delta t), I_{tI}(t-i \cdot \Delta t), \end{array} \right\} i = 1, 2, \dots, Ni. \quad (4.4)$$

Donde $E_{tR}(t-i \cdot \Delta t)$, y $E_{tI}(t-i \cdot \Delta t)$ corresponden al componente real e imaginario de la tensión en terminales de la máquina en el instante $(t-i \cdot \Delta t)$ con $i=1,2,\dots, Ni$ y Δt es el paso de tiempo empleado en la simulación. Por otro lado, $I_{tR}(t-i \cdot \Delta t)$, y $I_{tI}(t-i \cdot \Delta t)$ representan el componente real e imaginario de la corriente en los mismos instantes de tiempo. Este conjunto de entradas es seleccionado para obtener una salida que corresponde al ángulo del rotor de la máquina (δ) en el tiempo t . El parámetro Ni , representa la cantidad de valores previos necesarios de cada variable de entrada de la red neuronal para estimar el valor de la salida en el instante t . Este parámetro es obtenido, junto con los demás que definen la arquitectura de la red neuronal, en la etapa de entrenamiento, según se describe en la sección 4.4.

En la figura 4.2 se presenta la red empleada para los propósitos de estimar el ángulo del rotor de la máquina síncrona, lo cual se ha denominado aquí como el modelo neuronal clásico de la máquina síncrona. En la sección 5.1, se presentan los resultados obtenidos para este modelo neuronal.

La desviación de la velocidad del rotor de la máquina no es estimada por la red neuronal, principalmente porque se puede obtener a partir de los valores del ángulo del rotor (δ), tomando




Figura 4.2: Red neuronal artificial propuesta para el modelo neuronal clásico

una aproximación numérica de la ecuación 4.3, la cuál se expresa como:

$$\frac{d\delta}{dt} = \omega_o \Delta\omega \cong \frac{\Delta\delta}{\Delta t}$$

Por lo tanto, la desviación de la velocidad del rotor puede estimarse por:

$$\Delta\omega(t) \cong \frac{1}{\omega_o} \cdot \frac{\Delta\delta(t)}{\Delta t} \quad (4.5)$$

Donde

$\Delta\delta(t) = \delta(t) - \delta(t - \Delta t)$, diferencia de ángulo del rotor, radianes eléctricos.

Δt = Paso de tiempo, s.

ω_o = velocidad angular nominal, radianes eléctricos/s.

4.2. Modelo neuronal de quinto orden de la máquina síncrona

La metodología empleada para la creación del modelo neuronal clásico es adaptada para la obtención de un modelo tipo caja negra de la máquina síncrona que replique el modelo de quinto orden mediante el uso de redes neuronales del tipo perceptrón multicapa (MLP). La creación de la base de datos para el entrenamiento de la red neuronal se realizó con el paquete de computador HAGP (Herramienta Software para el Análisis de Estabilidad de Gran Perturbación de Sistemas Eléctricos de Potencia) elaborado por [Sierra, 2007; Sierra, 2003].

4.2.1. Modelo de quinto orden de la máquina síncrona

El modelo de quinto orden considerado es típico en la representación de generadores acoplados a turbinas hidráulicas [Sierra, 2007]. El modelo representa la dinámica de tres circuitos rotóricos, dos en el eje directo y uno en el eje en cuadratura, así como la inercia mecánica del rotor. Según lo descrito en el apéndice A.1, el modelo con tres circuitos rotóricos tendrá cinco variables de estado, dos variables que representan la dinámica del movimiento ($\delta, \Delta\omega$) y las demás están definidas en la dinámica del circuito del rotor ($\psi_{fd}, \psi_{ld}, \psi_{lq}$). Asociadas a estas variables de estado están las variables que representan la tensión en el estator, las cuales se pueden representar en el marco de referencia R-I según:

$$\begin{bmatrix} E_R \\ E_I \end{bmatrix} = \begin{bmatrix} -R_{RR} & X_{RI} \\ -X_{IR} & -R_{II} \end{bmatrix} \begin{bmatrix} I_R \\ I_I \end{bmatrix} + \begin{bmatrix} E_R'' \\ E_I'' \end{bmatrix} \quad (4.6)$$

Donde los elementos de la matriz de impedancia son descritos en las ecuaciones A.23 a A.26 del apéndice A.

Según [Kundur, 1994], del análisis de la expresión 4.6, se puede deducir que si se desprecia el efecto de los polos salientes en el periodo subtransitorio, $L_d'' = L_q''$; entonces:

$$R_{RR} = R_{II} = R_a$$

$$X_{RI} = X_{IR} = \bar{\omega} L_d'' = X_d'' = X_q'' = X''$$

Por lo tanto, $E'' = E_R'' + jE_I''$ representan la tensión antes de la impedancia subtransitoria $Z'' = R_a + jX''$.

Entonces, para la solución de las ecuaciones de la red de transmisión, el generador puede ser representado por el circuito equivalente mostrado en la figura 4.3.





Figura 4.3: Circuito equivalente de la máquina síncrona despreciando el efecto de los polos salientes en el periodo subtransitorio.

Sin embargo, del análisis del conjunto completo de ecuaciones que representan el modelo de la

máquina síncrona, se puede sugerir que la expresión 4.6, puede resumir la dinámica rotórica de la máquina ante la red del sistema de potencia, por medio de las variables E_R'' , E_I'' , R_{RR} , R_{II} , X_{IR} y X_{RI} ; por lo cual, se propone el esquema matricial de la expresión 4.6 como la representación de la máquina síncrona para la solución de las ecuaciones de la red de transmisión según la figura 4.4.



$$Y'' = Z^{-1}$$

$$I'' = Y'' \cdot E''$$

Figura 4.4: Circuito propuesto para la representación de la máquina síncrona

Adicionalmente, el modelo propuesta de quinto orden, se propone con un sistema de excitación con regulador de voltaje automático (AVR), según se describe en el apéndice A (sección A.2). Dicho sistema tiene asociada una variable de estado (v_1) cuya dinámica esta descrita por la ecuación A.37. La figura A.5 presenta el esquema del sistema de excitación AVR. Se puede observar que el sistema tiene una variable de entrada (E_t) y una variable de salida E_{fd} , entonces el diagrama presentado en la figura 4.5 representa el modelo de tipo caja negra de este sistema de excitación.

4.2.2. Desarrollo del modelo neuronal de quinto orden

Para la representación del modelo de quinto orden de la máquina síncrona por medio de redes neuronales, se propone la separación de la dinámica de la máquina y el sistema de excitación.



Figura 4.5: Esquema de excitación AVR simplificado como modelo tipo caja negra

Entonces el modelo neuronal de quinto orden está compuesto por dos ANN interconectadas, una que representa en conjunto la dinámica del movimiento y la dinámica del circuito del rotor, y la otra, que replica el sistema de excitación. A continuación se presentan los aspectos más importantes para el ajuste de las redes neuronales planteadas.

El objetivo de la primera red neuronal es representar la máquina síncrona según el esquema propuesto en la figura 4.4. Nótese que las variables de interés para el modelo son E_R'' , E_I'' , R_{RR} , R_{II} , X_{IR} y X_{RI} , puesto que la tensión ($E_t = E_R + jE_I$) y la corriente ($I_t = I_R + jI_I$) en terminales son variables que se establecen luego de la interacción de la máquina con el sistema de potencia. Además las variables R_{RR} , R_{II} , X_{IR} y X_{RI} definidas en las ecuaciones A.23 a A.26 solo dependen de una variable de estado, el ángulo del rotor δ , y de los parámetros fijos de la máquina síncrona (Resistencia interna R_a y Reactancias subtransitorias X_d'' y X_q''), por lo tanto, el circuito propuesto en la figura 4.4, queda bien definido, estimando las variables E_R'' , E_I'' , y δ .

Adicionalmente, en el esquema propuesto para el modelo del sistema de excitación presentado en la figura 4.5 se observa que la salida del sistema no es definida por ninguna variable de estado, solo por la tensión en terminales. Por lo tanto, el conjunto de variables seleccionado como objetivo de estimación de la red neuronal será $(\delta, E_R'' y E_I'')$. La primera variable (δ), representa la dinámica del movimiento de la máquina, aunque no se considere la desviación de la velocidad en el rotor, esta estimación se puede hacer de manera numérica si de tiene el valor del ángulo del rotor según la ecuación 4.5. Las otras dos ($E_R'' y E_I''$), se pueden considerar como la representación de la dinámica de los circuitos del rotor y los efectos de saturación. Con la estimación de este conjunto de variables, la máquina síncrona queda representada en un sistema de potencia y de su interacción se podrá calcular la corriente y tensión en terminales de la máquina.

Como entradas de la red neuronal se seleccionaron aquellas variables que suministran información de la interacción de la máquina con el sistema interconectado, dichas variables son la magnitud de la tensión E_t y corriente I_t en terminales, y la potencia activa P_t y reactiva Q_t suministrada por la máquina. Además, se debe tener en cuenta la interacción de la máquina con el sistema de excitación, por lo cual, la tensión de campo E_{fd} , también es seleccionada como entrada de la red neuronal. Entonces, la función objetivo del modelo neuronal de quinto orden se expresa como:

$$\begin{bmatrix} \delta(t), \\ E_R''(t), E_I''(t) \end{bmatrix} = f \left\{ \begin{array}{c} E_t(t-i \cdot \Delta t), I_t(t-i \cdot \Delta t), E_{fd}(t-i \cdot \Delta t), \\ P_t(t-i \cdot \Delta t), Q_t(t-i \cdot \Delta t) \end{array} \right\} \text{ con } i = 1, 2, 3, \dots, Ni \quad (4.7)$$

Donde $E_t(t-i \cdot \Delta t)$, $I_t(t-i \cdot \Delta t)$, corresponden a la magnitud de la tensión y corriente en terminales de la máquina en el instante $(t-i \cdot \Delta t)$ con $i=1,2,\dots, Ni$ y Δt es el paso de tiempo empleado en la simulación. Por otro lado, P_t y Q_t representan la potencia activa y reactiva suministrada por la máquina en los mismos instantes de tiempo. Finalmente, E_{fd} corresponde con la tensión de campo suministrada por el sistema de excitación en los instantes de tiempo mencionados. El conjunto total de entrada es seleccionado para obtener tres salidas que corresponden al ángulo del rotor de la máquina (δ) y la componente real (E_R'') e imaginaria (E_I'') de la tensión antes de la impedancia subtransitoria de la máquina en el tiempo t .

El parámetro Ni , representa la cantidad de valores previos necesarios de cada variable de entrada de la red neuronal para estimar el valor de la salida en el instante t . Este parámetro es obtenido, junto con los demás que definen la arquitectura de la red neuronal, en la etapa de entrenamiento, según se describe en la sección 4.4. En la figura 4.6 se presenta la red neuronal propuesta como el modelo neuronal de quinto orden de la máquina síncrona.

La segunda red neuronal es propuesta para replicar el comportamiento del sistema de excitación presentado en la figura A.5. Como se mencionó anteriormente, dicho sistema se queda representado por la relación existente entre la variables del esquema 4.5, donde la tensión en terminales E_t es la variable de entrada y la tensión de campo E_{fd} es la única variable de salida. Sin embargo, debido a la compleja relación entre dichas variables, se debe tomar información de la tensión de campo para realimentar la red. Por lo tanto, la función objetivo para el modelo neuronal del sistema de excitación queda expresada como:

$$[E_{fd}(t)] = f \left\{ E_t(t-i \cdot \Delta t), E_{fd}(t-i \cdot \Delta t) \right\} \text{ con } i = 1, 2, 3, \dots, Ni \quad (4.8)$$

Donde $E_t(t-i \cdot \Delta t)$, corresponde a la magnitud de la tensión en terminales de la máquina en el instante $(t-i \cdot \Delta t)$ con $i=1,2,\dots, Ni$ y Δt es el paso de tiempo empleado en la simulación. Así mismo, $E_{fd}(t-i \cdot \Delta t)$, es la tensión de campo aplicada a la máquina en los mismos instantes de tiempo. El conjunto de entradas seleccionadas estiman la única salida de la red neuronal que corresponde a la tensión de campo E_{fd} aplicada a la máquina en el instante t . Sin embargo, la tensión de campo E_{fd} estimada por la red neuronal, no esta limitada por los valores máximo (E_{FMAX}) y mínimo (E_{FMIN}) considerados en el esquema de la figura A.5, debido a limitaciones propias de la red neuronal, por lo tanto al modelo propuesto en la figura 4.5, debe agregarse el limitador de tensión de campo presente en el diagrama A.5. En la figura 4.7 se presenta la red neuronal propuesta para replicar el comportamiento del sistema de excitación con regulador de voltaje automático (AVR).

La figura 4.8 presenta el modelo neuronal de quinto orden de la máquina síncrona que incluye




Figura 4.6: Red Neuronal propuesta para el modelo neuronal de quinto y octavo orden de la máquina síncrona.

el sistema de regulación de tipo AVR, propuesto en este trabajo de investigación. En la sección 5.2, se presentan los resultados obtenidos para el modelo neuronal de quinto orden.




Figura 4.7: Red Neuronal propuesta para el sistema de excitación AVR




Figura 4.8: Modelo Neuronal de Quinto Orden Completo (Máquina + AVR)

4.3. Modelo neuronal de octavo orden de la máquina síncrona

4.3.1. Modelo de octavo orden de la máquina síncrona

El modelo de octavo orden considerado es el que se utiliza para representar turbo-generadores cuya dinámica no sea adecuadamente descrita por un modelo de sexto orden [Sierra, 2007]. El modelo representa la dinámica de seis circuitos rotóricos, tres en el eje directo y tres en el eje en cuadratura, así como la inercia mecánica del rotor. Según lo descrito en el apéndice A.1, el modelo con seis circuitos rotóricos tendrá ocho variables de estado, dos variables que representan la dinámica del movimiento ($\delta, \Delta\omega$) y las demás están asociadas a la dinámica del circuito del rotor ($\psi_{fd}, \psi_{1d}, \psi_{2d}, \psi_{1q}, \psi_{2q}, \psi_{3q}$).

Sin embargo, del análisis presentado en [?] y expuesto en la sección 4.2.1 de la expresión 4.6, se puede estimar que la dinámica rotórica de la máquina con el modelo de octavo orden, también puede ser representada por el equivalente de la figura 4.4.

Finalmente, el modelo de la máquina síncrona de octavo orden considerado en esta investigación esta previsto de un sistema de excitación el cual consta de un regulador de voltaje automático (AVR) y un sistema estabilizador de potencia (PSS), según se describe en el apéndice A (sección A.2). Dicho sistema tiene asociado tres variables de estado (v_1, v_2, v_3) cuya dinámica esta descrita por las ecuaciones A.37, A.38 y A.39, respectivamente. Sin embargo, de la figura A.4, la cual presenta el diagrama del sistema de excitación considerado, se puede apreciar que dicho sistema esta definido por dos variables de entrada, la tensión en terminales E_t y la desviación en la velocidad $\Delta\omega$, y una variable de salida, la tensión de campo E_{fd} . Por lo tanto, el diagrama de bloques de la figura A.4 puede ser descrito por un modelo tipo caja negra con dos entradas y una salida, como se muestra en la figura 4.9. Esta representación es mas conveniente para el mapeo de la red neuronal, puesto que involucra menos variables y puede reducir los cálculos de lograrse una replica de la dinámica del mismo.




Figura 4.9: Esquema de excitación AVR y PSS simplificado como modelo tipo caja negra

4.3.2. Desarrollo del modelo neuronal de octavo orden

Partiendo del análisis expuesto para el modelo de quinto orden, la representación del modelo de octavo orden de la máquina síncrona por medio de redes neuronales, también tiene presente la separación de la dinámica de la máquina y el sistema de excitación. Entonces el modelo neuronal

de octavo orden está compuesto por dos ANN interconectadas, una que representa en conjunto la dinámica del movimiento y la dinámica del circuito del rotor, y la otra, que replica el sistema de excitación.

Al igual que el modelo neuronal de quinto orden, el objetivo de la primera red neuronal es representar la máquina síncrona según el esquema propuesto en la figura 4.4. Por lo tanto, siguiendo el mismo análisis expuesto en la sección 4.2.1, el circuito propuesto en la figura 4.4, queda bien definido, estimando las variables E_R'' , E_I'' , y δ .

Adicionalmente, en el esquema propuesto para el modelo del sistema de excitación presentado en la figura 4.9 se observa que la salida del sistema es definida por la variable de estado asociada a la desviación de la velocidad rotórica ($\Delta\omega$) y la tensión en terminales. Debido a que la tensión en terminales depende de la interacción de la máquina con el sistema al cual este conectado, la variable de interés a estimar es solamente la desviación de la velocidad rotórica. Sin embargo, de la ecuación 4.5, se puede apreciar que la desviación de la velocidad del rotor, es una variable que depende directamente del ángulo del rotor δ , razón por la cual se propone no incluir a la desviación de la velocidad rotórica ($\Delta\omega$) como variable a estimar por la red neuronal.

Por lo tanto, el conjunto de variables seleccionado como objetivo de estimación de la red neuronal es el mismo que para el modelo neuronal de quinto orden, representado por $(\delta, E_R'' \text{ y } E_I'')$. Con la estimación de este conjunto de variables, la máquina síncrona queda representada en un sistema de potencia y de su interacción se podrá calcular la corriente y tensión en terminales de la máquina.

Como entradas de la red neuronal se seleccionaron las mismas que para el modelo de quinto orden. Entonces, la función objetivo del modelo neuronal de octavo orden se expresa según la ecuación 4.7, que corresponde a la función objetivo del modelo neuronal de quinto orden. Aunque los dos modelos neuronales al parecer tienen la misma función objetivo, no es así, puesto que el parámetro N_i y los parámetros asociados a la arquitectura de la red (número de capas y neuronas por capa), pueden ser diferentes en cada modelo, por lo cual el número real de entradas a la red neuronal será diferente.

En la figura 4.6 se presenta la red neuronal propuesta como el modelo neuronal de octavo orden de la máquina síncrona.

La segunda red neuronal es propuesta para replicar el comportamiento del sistema de excitación presentado en la figura A.4. Como se mencionó anteriormente, dicho sistema se queda representado por la relación existente entre las variables del esquema 4.9, donde la tensión en terminales E_t y la desviación en la velocidad $\Delta\omega$, son las variables de entrada y la tensión de campo E_{fd} es la única variable de salida. Sin embargo, como se mencionó anteriormente, la desviación en la velocidad $\Delta\omega$ está directamente relacionada con el ángulo del rotor, por lo cual se propone no considerar a la desviación de la velocidad del rotor como variable de entrada a la red neuronal y en su lugar se considera el ángulo del rotor como entrada al sistema de excitación neuronal. Adicionalmente, dada la complejidad del modelo planteado, se hace necesario información adicional; esta información se puede obtener de realimentar la tensión de campo estimada por la red neuronal en los instantes

anteriores. Por lo tanto, la función objetivo para el modelo neuronal del sistema de excitación queda expresada como:

$$[E_{fd}(t)] = f \left\{ E_t(t - i \cdot \Delta t), \delta(t - i \cdot \Delta t), E_{fd}(t - i \cdot \Delta t) \right\} \text{ con } i = 1, 2, 3, \dots, N_i \quad (4.9)$$

Donde $E_t(t - i \cdot \Delta t)$, corresponde a la magnitud de la tensión en terminales de la máquina en el instante $(t - i \cdot \Delta t)$ con $i=1,2,\dots, N_i$ y Δt es el paso de tiempo empleado en la simulación. Así mismo, $\delta(t - i \cdot \Delta t)$ y $E_{fd}(t - i \cdot \Delta t)$, son el ángulo de rotor y la tensión de campo de la máquina en los mismos instantes de tiempo. La única salida de la red neuronal corresponde a la tensión de campo E_{fd} aplicada a la máquina en el instante t . El parámetro N_i , representa la cantidad de valores previos necesarios de cada variable de entrada de la red neuronal para estimar el valor de la salida en el instante t . Este parámetro es obtenido, junto con los demás que definen la arquitectura de la red neuronal, en la etapa de entrenamiento, según se describe en la sección 4.4.

En la figura 4.10 se presenta la red neuronal propuesta para replicar el comportamiento del sistema de excitación con regulador de voltaje automático (AVR) y sistema estabilizador de potencia (PSS). Nótese que el esquema propuesto tiene incluido un limitador en la tensión de campo E_{fd} estimada por la red neuronal, puesto que, la salida de la red neuronal no esta limitada por los valores máximo (E_{FMAX}) y mínimo (E_{FMIN}) considerados en el esquema de la figura A.4, debido a limitaciones propias de la red neuronal, por lo tanto el modelo propuesto en la figura 4.9, debe se complementado con el limitador de tensión de campo presente en el diagrama A.4.

La figura 4.11 presenta el modelo neuronal de octavo orden de la máquina síncrona propuesto en este trabajo de investigación, el cual incluye el sistema de regulación de tipo AVR con PSS de la figura A.4. En la sección 5.3, se presentan los resultados obtenidos para el modelo neuronal de octavo orden.

4.4. Definición de la arquitectura del modelo neuronal

La red neuronal utilizada para replicar los modelos neuronales planeados anteriormente es del tipo perceptrón multicapa feed-forward. Las funciones de activación utilizadas son la tangente hiperbólica (en Matlab® tansig), y lineal pura (purelin). La función purelin realiza un mapeo de la entrada a través de una línea recta de pendiente unitaria tal como se expresa en 4.10. Por otro lado, la función tansig representa una función tangente hiperbólica, que es una función continua no lineal con un rango comprendido entre -1 y 1, tal como se presenta en 4.11.

$$purelin(x) = x \quad (4.10)$$




Figura 4.10: Red Neuronal propuesta para el sistema de excitación AVR con PSS




Figura 4.11: Modelo Neuronal de Octavo Orden Completo (Máquina + AVR con PSS)

$$\text{tansig}(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (4.11)$$

La función de activación para las neuronas de la capa oculta es la tangente hiperbólica y para las neuronas de salida es la función de activación lineal.

Para el desarrollo de los modelos neuronales, se utilizó el módulo de redes neuronales de MATLAB® [Demuth et al., 2006]. Los pesos y los umbrales iniciales son valores aleatorios entre 0 y 1. Las entradas son normalizadas a valores entre -1 y 1.

Los parámetros a definir en la arquitectura de la red neuronal son el número de capas ocultas, el número de neuronas en cada capa oculta y la cantidad de valores previos necesarios de cada variable de entrada de la red neuronal (N_i). Este conjunto de parámetros son determinados experimentalmente de acuerdo al estudio del comportamiento de la red durante el proceso de entrenamiento, teniendo en cuenta algunos factores como la velocidad de convergencia, el criterio de error, entre los más importantes. A continuación se presenta un breve resumen de la etapa de entrenamiento de las redes neuronales.

La arquitectura del modelo neuronal clásico de la máquina síncrona, se supone la más sencilla entre los modelos propuestos, debido a esto, se propone una sola capa oculta en la arquitectura de la red neuronal de la figura 4.2. Por lo tanto, el proceso de entrenamiento debe determinar solo dos parámetros, el número de neuronas de la capa oculta y la cantidad de valores previos necesarios de cada variable de entrada de la red neuronal (N_i).

Dentro de los parámetros del algoritmo de entrenamiento se encuentra el error medio cuadrático (MSE) de meta y el número máximo de épocas. Para esta prueba se asigna una meta muy baja (10^{-10}), con el fin de que el algoritmo no converja rápido y se aprecie el óptimo desempeño de la red para un número máximo de 3000 épocas de aprendizaje. La figura 4.12 muestra la variación del número de neuronas en la capa oculta y el error medio cuadrático (MSE) de la etapa de prueba de la red neuronal al final del entrenamiento para diferentes valores de N_i . De esta figura se observa que los mejores comportamientos (menor MSE) se obtienen para las combinaciones (N_i , Neuronas) = (3, 45); (4, 55); (5, 35) con MSE de $8,79 \times 10^{-9}$, $8,84 \times 10^{-9}$ y $9,16 \times 10^{-9}$, respectivamente. Otro hecho a resaltar es que para $N_i = 2$, el MSE nunca estuvo por debajo de 10^{-7} . También se puede observar que en ningún caso el MSE de la red llega a la meta propuesta, sin embargo, un error cercano a 10^{-8} , se puede considerar apropiado para resultados de una simulación numérica en el dominio del tiempo.

En la figura 4.13 se muestra la variación de la velocidad de convergencia del modelo neuronal clásico (medida en épocas) respecto al número de neuronas presente en la capa oculta. Para observar la velocidad de convergencia se plantea un esquema de entrenamiento con una meta de error no tan exigente pero aceptable para este caso (10^{-7}) y se centra la atención al número de épocas necesario para lograr la meta de error. En base a esa información, el parámetro N_i es ajustado a (3) tres y el número de neuronas en la capa oculta utilizado es de (45) cuarenta y cinco, puesto que presenta una




Figura 4.12: Desempeño de las arquitecturas del modelo neuronal clásico

convergencia apropiada y un error medio cuadrático global más bajo. Adicionalmente se observa que el aumento de neuronas no siempre mejora el rendimiento global de la red neuronal artificial, pero si aumenta el esfuerzo computacional.

El mismo procedimiento se sigue para determinar la arquitectura del modelo neuronal de quinto y octavo orden. A manera de resumen, en la figura 4.14 se muestra el desempeño de la red neuronal que replica el modelo de quinto orden, se plasman las arquitecturas que mejor comportamiento presentaron durante el proceso de entrenamiento para un N_i igual a (6) seis. De esta gráfica se observa que la arquitectura con dos capas ocultas, de 30 y 10 neuronas, respectivamente, tiene el menor error en la etapa de prueba, por lo cual, el modelo neuronal de quinto orden es adaptado con esa arquitectura.

En la figura 4.15 se presenta el resumen del desempeño para diversas arquitecturas de la red neuronal propuesta para el modelo de octavo orden, donde de nuevo el parámetro N_i resulta ser (6) seis, es decir, el mejor comportamiento se presenta cuando se toman seis datos previos en las variables de entrada a la red neuronal. De la información contenida y del proceso de entrenamiento se estiman dos capas ocultas, cada una con 25 neuronas.

En la Tabla 4.1 se presentan los resultados obtenidos en el proceso de entrenamiento de las redes propuestas.




Figura 4.13: Velocidad de convergencia del modelo Neuronal Clásico




Figura 4.14: Desempeño arquitecturas modelo neuronal de quinto orden

	Modelo Clásico	Modelo Quinto Orden		Modelo Octavo Orden	
Parámetro	Máquina	Máquina	AVR	Máquina	AVR con PSS
Cantidad Valores previos (N_i)	3	6	4	6	6
No. Capas	1	2	1	2	2
No. Neuronas por Capa	45	[30 10]	40	[25 25]	[20 10]

Tabla 4.1: Definición de la Arquitectura de los modelos neuronales propuestos.




Figura 4.15: Desempeño arquitecturas modelo neuronal de octavo orden

Capítulo 5

Pruebas y Resultados

Este capítulo presenta las pruebas y los resultados numéricos obtenidos al aplicar la metodología propuesta en el capítulo 4 para la simulación de la dinámica de la máquina síncrona en estudios de estabilidad. La validez de tales resultados será comprobada mediante la comparación con los resultados obtenidos utilizando el paquete de computador HAGP (Herramienta Software para el Análisis de Estabilidad de Gran Perturbación de Sistemas Eléctricos de Potencia) elaborado por [Sierra, 2007; Sierra, 2003].

5.1. Resultados obtenidos del modelo neuronal clásico

La red neuronal propuesta en 4.1 se prueba en el sistema de potencia presentado en la figura 5.1. El sistema consiste en una estación de generación compuesta por 4 máquinas de 555 MVA, 24 kV y 60 Hz, que supe potencia a una barra infinita conectada a través de dos líneas de transmisión. Esta configuración simple es muy útil en la compresión de conceptos y efectos básicos en estabilidad transitoria [Kundur, 1994; Anderson y Fouad, 1997].




Figura 5.1: Sistema de una máquina conectado a una barra infinita

Los generadores son modelados como uno equivalente representado por el modelo clásico con los parámetros expresados en por unidad con la base de 2220 MVA (4×555), 24 kV y 60 Hz, con

una constante de inercia (H) de 3,5 MW×s/MVA, coeficiente de amortiguamiento (KD) igual a cero, reactancia transitoria (X_d) de 0,3 p.u. Los efectos del gobernador de velocidad son despreciados.

Los valores de reactancias del transformador y las líneas de transmisión están dados en por unidad en la misma base y referidas al lado de baja tensión del transformador, así: reactancia del transformador de 0,15; reactancias de las líneas 1 y 2 iguales a 0,5 y 0,93 respectivamente. Los valores de las resistencias se asumen muy pequeños por lo cual se consideran despreciables.

El punto de operación inicial del generador expresado en por unidad está dado por: $P=0,9$; $Q=0,436$ (sobreexcitado); $E_t = 1,0 \angle 28,34^\circ$; $V_{inf} = 0,90081 \angle 0^\circ$.

Un sistema de potencia puede estar sujeto a diferentes clases de disturbios, por lo que resulta complejo utilizar todas las respuestas del sistema ante diferentes disturbios en el conjunto de entrenamiento. Para el análisis aquí presentado, se considera el sistema sujeto a cortocircuitos trifásicos en la línea de transmisión identificada como L2. Todas las fallas trifásicas son realizadas a los 0,1 segundos de simulación y éstas son despejadas sacando de servicio la línea fallada. Esta es una práctica común en estudios de estabilidad. Todos los disturbios fueron aplicados para el sistema en la misma condición de operación (aprox. 2000 MW).

En total se emplean 20 situaciones para el ajuste y prueba de la red. Una situación corresponde a la liberación de la falla trifásica en un tiempo determinado comprendido entre 10 ms y 120 ms. Cada situación simulada genera como máximo aproximadamente 600 pares de entradas/salida (que corresponde con cada punto en el tiempo 3s/5ms), y así, la información ingresada a la red consiste en datos para cada instante de tiempo de las tensiones y corrientes en terminales y el ángulo del rotor del generador. El esquema de entrenamiento es basado en el expuesto en [Barrera et al., 2007a]. Entonces, para el conjunto de entrenamiento se toman el 80 % de los datos disponibles, que consiste en seleccionar aleatoriamente 16 de las 20 situaciones simuladas. Como datos de prueba para la red neuronal se utilizan 4 (20 %) situaciones diferentes a las de entrenamiento. Adicionalmente de los datos de entrenamiento se toman aleatoriamente 2 situaciones para ingresarlas al algoritmo de entrenamiento como datos de validación.

En la figura 5.2 se presenta el desempeño de la red neuronal empleada para la estimación del modelo clásico. Se observa que el error medio cuadrático en la etapa de entrenamiento y prueba siempre fue menor a 10^{-8} .

El conjunto de datos para entrenamiento y validación de la red neuronal son obtenidos por medio de simulación a partir del modelo clásico del generador síncrono. El intervalo de tiempo para las simulaciones es de 3 segundos para el caso estable o críticamente estable, mientras que para el caso inestable la simulación se detiene cuando el ángulo llega a 180 grados (situación que presenta un serio problema de inestabilidad). La duración de la simulación se elige de 3 s por inspección de la respuesta de la máquina (la onda resultante presenta completamente su tendencia en todos los casos antes de los 3 s). La frecuencia de muestreo es de 200 Hz.

Los resultados obtenidos para los tres casos (estable, críticamente estable e inestable) son presentados y comparados contra los valores obtenidos con el modelo clásico del generador síncrono,




Figura 5.2: Desempeño del Modelo Neuronal Clásico ante las diferentes épocas de entrenamiento

tal como se presenta en las figuras 5.3, 5.5y 5.7. Para el caso de las figuras mencionadas, éstas se muestran en una misma escala para el ángulo del rotor, con el fin de facilitar la comparación. El tiempo de despeje crítico (TDC) para el sistema de potencia en el punto de operación analizado es de 0.087 segundos. Si el tiempo de despeje es mucho menor que este valor, la respuesta del sistema siempre es estable.

a. Caso estable (Tiempo de despeje menor que el TDC)

La evolución del ángulo del rotor (el obtenido a partir del modelo clásico y el estimado por la ANN) para el caso estable con un tiempo de despeje de 0.04 segundos es ilustrada en la figura 5.3. En este gráfico no se percibe diferencia considerable entre el valor estimado y el obtenido con el modelo clásico, mostrando la buena adaptación de la ANN propuesta. En la figura 5.4 se muestra como detalle de la figura 5.3, una ventana de sólo 0.1 segundos en un punto de inflexión, para evidenciar cómo el algoritmo propuesto con base en NN sigue al desarrollado con el método clásico, con un error muy pequeño. El error medio cuadrático calculado para este caso es de $3,27 \times 10^{-8}$.




Figura 5.3: Comparación de la estimación del Ángulo del rotor para un caso estable (Modelo Clásico)




Figura 5.4: Detalle de la comparación de la estimación del Ángulo del rotor para un caso estable (Modelo Clásico)




Figura 5.5: Comparación de la estimación del Ángulo del rotor para un caso críticamente estable (Modelo Clásico)




Figura 5.6: Detalle de la comparación de la estimación del Ángulo del rotor para un caso críticamente estable (Modelo Clásico)




Figura 5.7: Comparación de la estimación del Ángulo del rotor para un caso inestable (Modelo Clásico)




Figura 5.8: Detalle de la comparación de la estimación del Ángulo del rotor para un caso inestable (Modelo Clásico)

b. Caso críticamente estable (Tiempo de despeje parecido al TDC)

Cuando la duración de la falla es muy cercana a TDC, la respuesta del sistema es críticamente estable. En la figura 5.5 se presenta el ángulo del rotor considerando un tiempo de despeje de 0.085 segundos. De igual manera que para el caso anterior, también se presenta un detalle de duración de 0.1 segundos y en un punto de inflexión de la gráfica, con el fin de observar cómo el algoritmo propuesto y basado en NN sigue el basado en un método clásico, tal como se muestra en la figura 5.6. El error medio cuadrático para este caso es de $6,8 \times 10^{-8}$.

c. Caso inestable (Tiempo de despeje mayor que el TDC)

El caso de una respuesta inestable del sistema (duración de la falla mucho mayor que TDC), se presenta en la figura 5.7. Se muestra cómo el valor del ángulo del rotor crece ante una duración de la falla de 0.92 segundos hasta pasar por el valor de π radianes a los 0,978 segundos. En la figura 5.8 se presenta un detalle de duración de 0.1 segundos de la gráfica 5.7, con el fin de observar cómo el algoritmo propuesto y basado en NN sigue el basado en un método clásico, tal como se había comprobado para los casos anteriores. El error medio cuadrático calculado para este caso es de $8,39 \times 10^{-8}$.

5.2. Resultados Obtenidos del modelo neuronal de quinto orden

Esta sección contiene los resultados obtenidos al aplicar la metodología propuesta en la sección 4.2 para el modelo neuronal de quinto orden en el sistema de potencia presentado en la figura 5.1.

El generador es modelado con su representación de quinto orden. Los parámetros en por unidad tomando como base 2220 MVA y 24 kV están contenidos en la tabla 5.1.

El generador está equipado con un sistema de excitación con regulador de voltaje automático (AVR) (ver figura A.5). Los parámetros están contenidos en la tabla 5.2.

Los resultados obtenidos para una tiempo de despeje de falla de 20 [ms] se muestran en las figuras 5.9 a la 5.12. Las figura 5.13 a la 5.16 son los resultados del mismo circuito pero considerando un tiempo de despeje de 60 [ms]. Todos los resultados son comparados con los resultados arrojados por el paquete de computador HAGP (Herramienta Software para el Análisis de Estabilidad de Gran Perturbación de Sistemas Eléctricos de Potencia) elaborado por [Sierra, 2007; Sierra, 2003].

Tabla 5.1: Parámetros del generador - Modelo de quinto orden

Parámetro	X_d	X_q	X'_d	X'_q	X''_d	X''_q	X_l	R_a	K_D
Valor	1,81	1,76	0,30	0,65	0,23	0,25	0,15	0,003	0
Parámetro	T'_{do}	T'_{qo}	T''_{do}	T''_{qo}	A_{sat}	B_{sat}	ψ_{t1}	ψ_{t2}	H
Valor	8s	1s	0,03s	0,07s	0,031	6,93	0,8	∞	3,5s

Tabla 5.2: Parámetros del sistema de excitación con AVR

Parámetro	K_A	T_R	E_{Fmax}	E_{Fmin}
Valor	200	0,015s	7,0	-6,4

5.3. Resultados Obtenidos del modelo neuronal de octavo orden

El sistema de prueba de la figura 5.1, considerado para el modelo clásico y de quinto orden es ahora considerado para el modelo de octavo orden.

La planta es modelada por medio de un generador equivalente cuyos parámetros en una base de 2220 MVA y 24 kV están contenidos en la tabla 5.3. El sistema de excitación utilizado es del tipo ST1A (ver figura A.4) con estabilizador. Los parámetros están contenidos en la tabla 5.4.

Los resultados para tiempos de despeje de falla de 30 ms y 80 ms pueden apreciarse en las figuras 5.17 a la 5.24.

Tabla 5.3: Parámetros del generador - Modelo octavo orden

Parámetro	X_d	X_q	X'_d	X'_q	X''_d	X'''_d	X''_q	X'''_q	R_a	X_l	X_{pl}	
Valor	1,81	1,76	0,30	0,65	0,23	0,0	0,25	0,0	0,003	0,15	0,0	
Parámetro	T'_{do}	T'_{qo}	T''_{do}	T'''_{do}	T''_{qo}	T'''_{qo}	A_{sat}	B_{sat}	ψ_{t1}	ψ_{t2}	H	K_D
Valor	8s	1s	0,03s	0,0s	0,07s	0,0s	0,031	6,93	0,8	∞	3,5s	0

Tabla 5.4: Parámetros del sistema de excitación con AVR con PSS

Parámetro	K_A	T_R	T_W	K_{STAB}	T_1
Valor	200	0,015s	1,41s	9,5	0,154s
Parámetro	T_2	E_{Fmax}	E_{Fmin}	V_{smax}	V_{smin}
Valor	0,033s	7,0	-6,4	0,2	-0,2

5.4. Caso de estudio: Efecto del sistema de excitación.

A manera de comparación se someten los modelos neuronales obtenidos a la misma situación característica en el sistema de la figura 5.1. Se considera una falla al segundo de iniciada simulación




Figura 5.9: Ángulo del rotor. Despeje de falla 20 [ms].

($t = 1$ s), y un tiempo de despeje de la falla de 70 ms. Para este caso sólo se presentaron los resultados obtenidos con los modelos neuronales y la validez de los resultados puede ser comprobada comparándolos con los resultados que han sido escaneados del ejemplo 13.2 del libro de [Kundur, 1994]. Los resultados para este caso se presentan en las figuras de la 5.25 a la 5.28.




Figura 5.10: Tensión en terminales. Despeje de falla 20 [ms].




Figura 5.11: Tensión de excitación. Despeje de falla 20 [ms].




Figura 5.12: Potencia Activa. Despeje de falla 20 [ms].




Figura 5.13: Ángulo del rotor. Despeje de falla 60 [ms].




Figura 5.14: Tensión en terminales. Despeje de falla 60 [ms].




Figura 5.15: Tensión de excitación. Despeje de falla 60 [ms].




Figura 5.16: Potencia Activa. Despeje de falla 60 [ms].




Figura 5.17: Ángulo del rotor. Despeje de falla 30 [ms].




Figura 5.18: Tensión en terminales. Despeje de falla 30 [ms].




Figura 5.19: Potencia activa. Despeje de falla 30 [ms].




Figura 5.20: Tensión de excitación. Despeje de falla 30 [ms].




Figura 5.21: Ángulo del rotor. Despeje de falla 80 [ms].




Figura 5.22: Tensión en terminales. Despeje de falla 80 [ms].




Figura 5.23: Potencia activa. Despeje de falla 80 [ms].




Figura 5.24: Tensión de excitación. Despeje de falla 80 [ms].




Figura 5.25: Comparación Ángulo del Rotor para los diferentes sistemas de Excitación. a) Modelos neuronales. b) Figura E13.7(a) de [Kundur, 1994]




Figura 5.26: Comparación: Potencia Activa para los diferentes sistemas de Excitación. a) Modelos neuronales. b) Figura E13.7(b) de [Kundur, 1994]




Figura 5.27: Comparación: Tensión en Terminales para los diferentes sistemas de Excitación. a) Modelos neuronales. b) Figura E13.7(c) de [Kundur, 1994]




Figura 5.28: Comparación: Tensión de Excitación para los diferentes sistemas de Excitación. a) Modelos neuronales. b) Figura E13.7(d) de [Kundur, 1994]

Capítulo 6

Conclusiones, aportaciones y sugerencias para posteriores desarrollos

En este capítulo final se presentan las conclusiones del desarrollo que se ha realizado en este proyecto de grado. En la primera sección se da una breve descripción del trabajo que se realizó y se mencionan las conclusiones obtenidas del mismo. En la segunda sección se detallan las aportaciones y en la última sección se ofrecen algunas sugerencias para posteriores desarrollos.

6.1. Resumen y conclusiones

El objetivo general de este trabajo de grado era emplear redes neuronales para representar el modelo de la máquina síncrona, basado en ecuaciones de Park, que se utiliza en estudios de estabilidad transitoria. Los resultados que se muestran en el capítulo anterior, indican que tal objetivo ha sido logrado satisfactoriamente. Los modelos neuronales propuestos replican la tendencia de las principales variables de la máquina síncrona, mostrando que la función de regresión propuesta captura la esencia dinámica de la máquina síncrona. Se pretende que los modelos desarrollados sirvan como base para futuros desarrollos y sean empleados satisfactoriamente en diversas actividades académicas. Las conclusiones obtenidas de esta tesis son:

- El modelo neuronal clásico de la máquina síncrona propuesto en esta investigación, replica la dinámica del ángulo rotor ante condiciones de falla, con medidas de las componentes real e imaginaria de tensión y corriente. En los casos analizados, el error cuadrático medio nunca estuvo por encima de 1×10^{-7} , lo cual demuestra gran adaptación del modelo a la dinámica de segundo orden de la máquina síncrona.
- Con el modelo neuronal propuesta de quinto y octavo orden, se puede reproducir la dinámica de la máquina síncrona con tres y seis circuitos rotóricos con un sistema de excitación del tipo regulador automático de voltaje (AVR) el cual puede incluir un sistema estabilizador de potencia (PSS).

- Con los valores previos de cinco magnitudes eléctricas en terminales de la máquina, los cuales son: la tensión, corriente, potencia activa, potencia reactiva y tensión de excitación (campo); se puede estimar las principales variables que definen la dinámica de la máquina síncrona. Sin embargo, pese a que la tendencia de la máquina en cada uno de los casos es replicada, las ondas estimadas bajo simulación con el modelo neuronal presentan diferencias notorias contra las obtenidas al resolver las ecuaciones diferenciales.
- Con los modelos propuestos, se evita la solución del problema de flujos de potencia asociado a la solución paso a paso de las ecuaciones diferenciales y algebraicas de la máquina síncrona. Este hecho, radica en que el modelo neuronal predice el valor de la tensión interna de la máquina, con lo cual se puede estimar la corriente que la máquina inyecta al sistema de potencia en un instante dado.
- Una vez replicada la función de regresión neuronal de la máquina síncrona para una secuencia en el tiempo y un paso de tiempo determinado, esta se puede interpolar para obtener secuencias diferentes con otros pasos de tiempo. Los modelos neuronales propuestos han sido obtenidos en base a simulación en el tiempo para un paso de tiempo de 5 [ms]. Sin embargo, bajo pruebas realizadas, se pudo estimar que el modelo neuronal se comporta de manera correcta para pasos de tiempo diferentes a 5[ms]. Específicamente, se ha comprobado la validez de los resultados con un paso de tiempo de 10 [ms] y 2 [ms].

6.2. Aportaciones originales

Las principales aportaciones de este trabajo de grado son las siguientes:

- Obtención de un modelo neuronal clásico de la máquina síncrona que reproduce la dinámica de segundo orden, con valores previos de las componentes real e imaginaria de la tensión y corriente en terminales de la máquina.
- Obtención de modelos neuronales de quinto y octavo orden que sirve como funciones de regresión para estimar el comportamiento de la máquina síncrona con tres y seis circuitos rotóricos.
- Se propone la arquitectura base de la función de regresión que sirve para replicar un modelo de la máquina síncrona. Dicha función de regresión puede ser obtenida por cualquier herramienta de inteligencia artificial.

6.3. Sugerencias para posteriores desarrollos

Como se ha mencionado, se espera que este trabajo de grado sirva como base para posteriores desarrollos e investigaciones, dentro de los cuales se pueden mencionar:

- La adaptación de otras herramientas de inteligencia artificial que obtenga mejores replicas de la función de regresión propuesta para cada modelo de la máquina síncrona.
- La implementación de otros sistemas de excitación de la máquina síncrona, con base en la metodología propuesta.
- La inclusión de modelos neuronales que representen sistemas de regulación carga-velocidad y turbina tales como: modelos de turbinas hidráulicas y térmicas con sus respectivos gobernadores.
- La inclusión de modelos neuronales que replique el comportamiento de cargas dinámicas.
- Elaboración de una interfaz que permita la simulación de diversos casos con los modelos neuronales de la máquina síncrona.
- La simulación de la respuesta del sistema en condiciones desbalanceadas.
- Establecer una relación entre los parámetros básicos de la máquina síncrona (Resistencia y reactancia interna, constante de inercia,...) y los parámetros de una red neuronal artificial (número de neuronas, pesos de cada neurona,...).

Apéndice A

Modelo general de la máquina síncrona en el análisis de estabilidad transitoria

La máquina síncrona, por sus características, es tal vez el elemento más complejo desde el punto de vista del modelamiento. El modelo utilizado, por supuesto, depende del tipo de estudio a realizar. Específicamente, para estudios de estabilidad de gran perturbación de ángulo, el modelo debe incluir aspectos tales como la saturación magnética, la dinámica de los circuitos del rotor y el efecto de los controles primarios (sistema de excitación y sistema de regulación carga-velocidad y turbina), ya que así lo exigen las características del fenómeno. El modelo presentado a continuación es el propuesto en [Kundur, 1994], el cual es empleado para la simulación en el dominio del tiempo por el paquete de computador HAGP (Herramienta Software para el Análisis de Estabilidad de Gran Perturbación de Sistemas Eléctricos de Potencia) elaborado por [Sierra, 2007; Sierra, 2003], herramienta que es empleada en este trabajo para la obtención de la base de datos de entrenamiento.

A.1. Representación de la máquina síncrona

Para ilustrar la implementación del modelo del generador síncrono para análisis de estabilidad transitoria, se asume que el generador es representado por un modelo con un circuito amortiguador en el eje directo (denotado como $1d$) y dos circuitos amortiguadores en el eje de cuadratura (denotado como $1q$ y $2q$). Sin embargo, las ecuaciones presentadas en este aparte pueden ser fácilmente modificadas para tener en cuenta un modelo con un número arbitrario de circuitos amortiguados. En las figuras A.1 y A.2, se muestran los circuitos equivalentes de eje directo y cuadratura, respectivamente. En estos circuitos se puede apreciar la relación entre flujos y corrientes.

A continuación se presenta un resumen de las ecuaciones de la máquina síncrona como un conjunto de ecuaciones diferenciales de primer orden, con el tiempo t en segundos, el ángulo del rotor δ en radianes eléctricos, y las demás cantidades en por unidad. Para una explicación mas detallada de este modelo puede consultar [Kundur, 1994; Kundur, 1985; Sierra, 2007; Sierra, 2003].




Figura A.1: Circuito amortiguador equivalente del eje directo




Figura A.2: Circuito amortiguador equivalente de eje en cuadratura

A.1.1. Ecuaciones de la dinámica de movimiento

$$\rho \Delta \omega = \frac{1}{2H} (T_m - T_e - K_D \Delta \omega) \quad (\text{A.1})$$

$$\rho \delta = \omega_o \Delta \omega \quad (\text{A.2})$$

donde

$\Delta \omega$ = desviación de velocidad rotórica, pu

δ = ángulo del rotor, radianes eléctricos

H = constante de inercia de la máquina, s

T_m = par mecánico, pu

T_e = par eléctrico, pu

K_D = Coeficiente de torque amortiguante, pu

$\omega_o = \frac{d}{dt}$ velocidad angular nominal, radianes eléctricos/s

ρ = operador, $\frac{d}{dt}$

A.1.2. Ecuaciones del circuito del rotor

Con las corrientes del rotor expresadas en términos de los encadenamiento de flujo del rotor y mutuo, las ecuaciones de la dinámica del circuito del rotor son:

$$\rho \psi_{fd} = \omega_0 \left[e_{fd} + \frac{(\psi_{ad} - \psi_{fd}) R_{fd}}{L_{fd}} \right] \quad (\text{A.3})$$

$$\rho \psi_{1d} = \omega_0 \left(\frac{\psi_{ad} - \psi_{1d}}{L_{1d}} \right) R_{1d} \quad (\text{A.4})$$

$$\rho \psi_{1q} = \omega_0 \left(\frac{\psi_{aq} - \psi_{1q}}{L_{1q}} \right) R_{1q} \quad (\text{A.5})$$

$$\rho \psi_{2q} = \omega_0 \left(\frac{\psi_{aq} - \psi_{2q}}{L_{2q}} \right) R_{2q} \quad (\text{A.6})$$

Donde los flujos ligados mutuos del eje directo y cuadratura se obtienen por:

$$\psi_{ad} = L_{ads}'' \left(-i_d + \frac{\psi_{fd}}{L_{fd}} + \frac{\psi_{1d}}{L_{1d}} \right) \quad (\text{A.7})$$

$$\psi_{aq} = L_{aqs}'' \left(-i_q + \frac{\psi_{1q}}{L_{1q}} + \frac{\psi_{2q}}{L_{2q}} \right) \quad (\text{A.8})$$

Donde:

$$\frac{1}{L_{ads}''} = \frac{1}{L_{ads}} + \frac{1}{L_{fd}} + \frac{1}{L_{1d}} \quad (\text{A.9})$$

$$\frac{1}{L_{aqs}''} = \frac{1}{L_{aqs}} + \frac{1}{L_{1q}} + \frac{1}{L_{2q}} \quad (\text{A.10})$$

Aquí L_{ads} y L_{aqs} son los valores saturados de las inductancias mutuas del eje directo y en cuadratura obtenidas como se describe mas adelante en la sección A.1.4.

A.1.3. Ecuaciones de tensión del estator

En [Kundur, 1994] se discute y propone para efectos de análisis de estabilidad transitoria, expresar la tensión en el estator despreciando los transitorios del estator ($\rho \psi_d, \rho \psi_q$) y la variación de velocidad (ω/ω_0). Teniendo en cuenta dicha aproximación, la tensión en el estator puede ser escrita como:

$$e_d = -R_a \cdot i_d + X_q'' \cdot i_q + E_d'' \quad (\text{A.11})$$

$$e_q = -R_a \cdot i_q - X_d'' \cdot i_d + E_q'' \quad (\text{A.12})$$

$$E_d'' = L_{aqs}'' \left(\frac{\psi_{1q}}{L_{1q}} + \frac{\psi_{2q}}{L_{2q}} \right) \quad (\text{A.13})$$

$$E_q'' = L_{ads}'' \left(\frac{\psi_{fd}}{L_{fd}} + \frac{\psi_{1d}}{L_{1d}} \right) \quad (\text{A.14})$$

$$X_d'' = L_l + L_{ads}'' \quad (\text{A.15})$$

$$X_q'' = L_l + L_{aqs}'' \quad (\text{A.16})$$

Las ecuaciones presentadas anteriormente se encuentran en el marco de referencia particular d-q el cual rota con el rotor de la máquina. Para la solución de las ecuaciones del sistema interconectado, estas se expresan en un marco de referencia común R-I que gira a velocidad sincrónica. Las expresiones que se utilizan para transformar las variables de un marco de referencia a otro son:

$$e_d = E_R \sin \delta - E_I \cos \delta \quad (\text{A.17})$$

$$e_q = E_I \sin \delta + E_R \cos \delta \quad (\text{A.18})$$

$$E_R = e_d \sin \delta + e_q \cos \delta \quad (\text{A.19})$$

$$E_I = e_q \sin \delta - e_d \cos \delta \quad (\text{A.20})$$

Las corrientes en el marco de referencia RI se expresan como:

$$I_R = \frac{R_{II}(E_R - E_R'') + X_{RI}(E_I - E_I'')}{R_{RR}R_{II} + X_{IR}X_{RI}} \quad (\text{A.21})$$

$$I_I = \frac{X_{IR}(E_R - E_R'') - R_{RR}(E_I - E_I'')}{R_{RR}R_{II} + X_{IR}X_{RI}} \quad (\text{A.22})$$

donde

$$R_{RR} = (X_d'' - X_q'') \sin \delta \cos \delta + R_a \quad (\text{A.23})$$

$$R_{II} = (X_q'' - X_d'') \sin \delta \cos \delta + R_a \quad (\text{A.24})$$

$$X_{RI} = X_d'' \cos^2 \delta + X_q'' \sin^2 \delta \quad (\text{A.25})$$

$$X_{IR} = X_d'' \sin^2 \delta + X_q'' \cos^2 \delta \quad (\text{A.26})$$

$$E_R'' = E_d'' \sin \delta + E_q'' \cos \delta \quad (\text{A.27})$$

$$E_I'' = E_q'' \sin \delta - E_d'' \cos \delta \quad (\text{A.28})$$

Bajo condiciones balanceadas las potencias activa y reactiva en terminales del generador son:

$$P_t = e_d i_d + e_q i_q \quad (\text{A.29})$$

$$Q_t = e_q i_d - e_d i_q \quad (\text{A.30})$$

y el torque eléctrico:

$$T_e = \psi_d i_q - \psi_q i_d = \psi_{ad} i_q - \psi_{aq} i_d = P_t + R_a I_t^2 \quad (\text{A.31})$$

La corriente de campo en el sistema por unidad se obtiene mediante:

$$i_{fd} = \frac{\psi_{fd} - \psi_{ad}}{L_{fd}} \quad (\text{A.32})$$

La corriente de salida del sistema excitador es:

$$I_{fd} = L_{adu} i_{fd} \quad (\text{A.33})$$

Las expresiones para los otros circuitos del rotor se hallan en forma similar. Los valores iniciales de las variables de estado son obtenidos a partir de los datos del flujo de carga (tensión y potencia en terminales). Hay que tener en cuenta que en estado estable la única corriente que circula en los circuitos del rotor es la corriente de campo.

A.1.4. Saturación magnética

En el desarrollo de las ecuaciones que describen el comportamiento de la máquina síncrona, se asumió que el circuito magnético era lineal y por consiguiente que era aplicable el principio de superposición. El análisis de la máquina síncrona considerando detalladamente los efectos de satu-

ración del circuito magnético es extremadamente complicado. Para incluir la saturación magnética en los modelos de la máquina, se han desarrollado métodos basados en aproximaciones justificadas y razonamientos empíricos. La idea es que los modelos mantengan un grado adecuado de simplicidad y exactitud. El método más aceptado para incluir los efectos de saturación en estudios de estabilidad consiste en variar las inductancias L_{ad} y L_{aq} en función del flujo resultante de entrehierro ψ_{at} . Las inductancias se calculan en función de factores de saturación:

$$L_{ad} = K_{sd}L_{adu} \quad (\text{A.34})$$

$$L_{aq} = K_{sq}L_{aqu} \quad (\text{A.35})$$

donde

K_{sd} = factor de saturación de eje directo

K_{sq} = factor de saturación del eje en cuadratura

L_{adu} = valor no saturado de L_{ad}

L_{aqu} = valor no saturado de L_{aq}

Los factores de saturación son calculados a partir de las características de circuito abierto de los ejes directo y en cuadratura.




Figura A.3: Característica de Saturación

Como indica la figura A.3, la característica de circuito abierto se divide en tres segmentos, el factor de saturación de eje directo se calcula como:

$$K_{sd} = \frac{\psi_{at}}{\psi_{at} + \psi_I} \quad (\text{A.36})$$

donde

$$\psi_I = 0 \text{ si } \psi_{at} \leq \psi_{T1}$$

$$\psi_I = A_{sat} e^{B_{sat}(\psi_{at} - \psi_{T1})} \text{ si } \psi_{T1} < \psi_{at} \leq \psi_{T2}$$

$$\psi_I = \psi_{G2} + L_{ratio}(\psi_{at} - \psi_{T2}) - \psi_{at} \text{ si } \psi_{at} > \psi_{T2}$$

$$\psi_{at} = \sqrt{\psi_{ad}^2 + \psi_{aq}^2}$$

$$\psi_{ad} = \psi_d + L_l i_d$$

$$\psi_{aq} = \psi_q + L_l i_q$$

El factor K_{sq} se calcula en forma similar. Para máquinas de polos salientes normalmente se toma $K_{sq} = 1$ y para máquinas de rotor cilíndrico $K_{sq} = K_{sd}$.

A.2. Representación del sistema de excitación

La función principal del sistema de excitación de una máquina síncrona es la de suministrar corriente directa al devanado de campo, con el fin de crear el campo magnético necesario para la conversión de energía. Adicionalmente, los sistemas de excitación cumplen con una serie de funciones de control y protección dentro de las que se encuentra el mejoramiento de la estabilidad del sistema de potencia. El requerimiento básico de desempeño del sistema de excitación es el regular automáticamente la tensión de campo con el fin de mantener la tensión en terminales de la máquina y el flujo de potencia reactiva en valores deseados, esta función debe llevarse a cabo sin causar daños a la máquina ni a los elementos del propio sistema de excitación.

Modelos para diferentes tipos de sistemas de excitación son descritos en [Kundur, 1994; Sierra, 2007]. Este trabajo considera los siguientes sistemas de excitación:

- Regulador de voltaje automático (AVR)
- Regulador de voltaje automático (AVR) con sistema estabilizador de potencia (PSS)

El Regulador de voltaje automático (AVR) con sistema estabilizador de potencia (PSS) (clasificado como tipo ST1A en [Kundur, 1994]), es mostrado en la figura A.4. Este sistema de excitación toma energía de los terminales del generador por medio de un transformador auxiliar [Sierra, 2003]. Las ecuaciones que describe la dinamica de este modelo son las siguientes:

$$\rho v_1 = \frac{1}{T_R} (E_t - v_1) \quad (\text{A.37})$$

$$\rho v_2 = K_{STAB} \cdot \rho \Delta \omega - \frac{1}{T_W} v_2 \quad (\text{A.38})$$

$$\rho v_3 = \frac{1}{T_2} [T_1 \cdot \rho v_2 + v_2 - v_3] \quad (\text{A.39})$$

La salida del estabilizador v_s es:

$$v_s = v_3 \quad (\text{A.40})$$

con

$$v_{smax} \geq v_s \geq v_{smin} \quad (\text{A.41})$$

La tensión de salida del excitador es:

$$E_{fd} = K_A [V_{ref} - v_1 + v_s] \quad (\text{A.42})$$

con

$$E_{Fmax} \geq E_{fd} \geq E_{Fmin} \quad (\text{A.43})$$

$$E_{Fmax} = V_{Rmax}E_t - K_c I_{fd} \quad (\text{A.44})$$

$$E_{Fmin} = V_{Rmin}E_t \quad (\text{A.45})$$




Figura A.4: Sistema de excitación con AVR y PSS

El regulador de voltaje automático (AVR) es presentado en la figura A.5. La dinamica de este sistema es mas sencilla que para el sistema que incluye PSS, las ecuación A.37 describe la dinamica de la variable de estado, mientras la tensión de excitación de salida es definida por las ecuaciones de la A.42 a la A.45.




Figura A.5: Sistema de excitación Regulador de Voltaje Automático (AVR)

El modelo de la máquina síncrona de quinto orden, se considera con el sistema de excitación regulador de voltaje automático. Por otro lado, el modelo de octavo orden es asociado con el sistema que incluye el estabilizador de potencia (PSS).

Bibliografía

- 1995 I. S. . “IEEE Guide: Test Procedures for Synchronous Machines, Part I-Acceptance and Performance Testing, Part II-Test Procedure and Parameter Determination for Dynamic Analysis”. 1995.
- Anderson P. M. y Fouad A. A. *Power System Control and Stability*. Iowa State University Press, Ames, Iowa, 1st. edition, 1997.
- Angel A. D., Geurts P., Ernst D., Glavic M. y Wehenkel L. “Estimation of rotor angles of synchronous machines using artificial neural networks and local PMU-based quantities”. *Neuro-computing 70 International Journal*, 2007.
- Angel A. D., Glavic M. y Wehenkel L. “Using Artificial Neural Networks to Estimate Rotor Angles and Speeds from Phasor Measurements”. *IEEE TRANSACTIONS ON INDUSTRIAL ELECTRONICS*, 2007.
- Aranguren S. y Muzachiodi S. *Implicancias del data mining. Capitulo 8: Redes Neuronales y algoritmos genéticos*. Tesis de grado, Sistemas de Información. Convenio UTN ISIPER, 2003.
- Barrera R., Morales G. y Mora J. “Determinacion de la distancia de falla en sistemas radiales empleando una estrategia de regresión basada en el método del vecino más cercano K-NN”. *IV Simposio Internacional Sobre la Calida de la Energía Eléctrica*, Manizales, Colombia. Noviembre 2007.
- Barrera R., Morales G. y Vargas H. “Análisis en el plano R-X para localizar fallas de alta impedancia”. *IV Simposio Internacional Sobre la Calida de la Energía Eléctrica*, Manizales, Colombia. Noviembre 2007.
- Boozari M. *State estimation and transient stability analysis in power systems using artificial neural networks*. 2004.
- Chapra S. C. y Canale R. P. *Métodos Numéricos para Ingenieros*. McGraw-Hill, 1996, 2da. edition.

- Chen S., Billings S. y Grant P. "Nonlinear identification using neural networks". *International Journal of Control*, Vol. 51, pp. 1191–1214, 1990.
- DeMarco C. L. y Qian R. X. "A New Result on Exit Time Calculations for Electric Power System Security Assesment". *Proc. of the 1986 Noth American Power Symposium*, Cornell University, Ithaca, New York. October 13-14 1986.
- Demuth H., Beale M. y Hagan M. *Neural networks Toolbox for use with MATLAB*. User guide, V. 5, The MathWorks Inc, 2006.
- Dong Z. Y. *Advanced Methods for Small Signal Stability Analisys and Control in Modern Power Systems*. Thesis Doctor of Philosophy in Electrical and Information Engineering, University of Sydney, 1998.
- Fitzgerald A. E., Kingsley C. y Umans S. D. *Electric Machinery*. McGraw-Hill, Inc., 5st. edition, 1990.
- Grainger J. J. y Stevenson W. D. *Analisis de Sistemas de Potencia*. McGraw-Hill, Inc., 1995.
- H. Bora Karayaka Ali Keyhani G. T. H. B. L. A. y Selin D. A. "Neural Network Based Modeling of a Large Steam Turbine-Generator Rotor Body Parameters From On-Line Disturbance Data". *IEEE TRANSACTIONS ON ENERGY CONVERSION*, VOL. 16, NO. 4, 2001.
- Haykin S. *Neural Networks a Compressive Foundation*. IEEE Press, New York, 1994.
- Kilgore L. "Calculation of Synchronous Machine Constants". *IEEE Trans*, Vol. 50, pp. 1201–1214, December 1931.
- Koester D., Ranka S. y Fox G. "Power Systems Transient Stability - A Grand Computing Challenge". *SCCS-549*, August 1992.
- Kundur P. "Evaluation of methods for studying power system stability". *Proc. International Symposium on Power System Stability*, 1985.
- Kundur P. *Power System Stability and Control*. McGraw-Hill, Inc., 1st. edition, 1994.
- Liu G. P., Billing S. A. y Kadiramanatan V. "Nonlinear System Identification Using Wavelet Networks". *IEE con*. pp 1248-1253, 1998.
- Looney C. *Pattern recognition using neural networks. Theory and Algorithms for Engineers and Scientists*. Oxford University Press, 1996.
- Molenaar D., Bosgra O. H. y Hoeijmakers M. J. "Identification of Synchronous Generator Transfer Function from Standstill Test Data". *Institute of Aeronautics and Astronomics, Inc and The American Society of Mechanical Engineers*, 2002.

- Mora J. *Localización de Faltas en Sistemas de Distribución de Energía Eléctrica usando Métodos Basados en el Modelo y Métodos Basados en el Conocimiento*. Tesis doctoral. Universidad de Girona, 2006.
- Mora J. y Pérez L. “Utilización de redes ANFIS y senales de corriente para localización de fallas en sistemas de distribución de energía eléctrica”. *Revista ingeniería e investigación*, Vol. 26, pp, 93-99, 2006.
- Morales G., Barrera R. y Mora J. “Reconocimiento de comandos por voz con máquinas de soporte vectorial a través de bandas espectrales”. *Revista Scientia et Técnica (ISSN 0122-1701)*, Vol. 37, diciembre 2007.
- Morales G. y Gómez A. *Estudio e implementación de una herramienta basada en Máquinas de Soporte Vectorial aplicada a la localización de fallas en sistemas de distribución*. Tesis de grado, Universidad Industrial de Santander, Bucaramanga, Colombia, 2005.
- Morales G., Mora J. y Carrillo G. “Evaluación comparativa de tres métodos de clasificación aplicados al problema de la localización de fallas de cortocircuito en sistemas de distribución de energía eléctrica”. *Revista Scientia et Técnica (ISSN 0122-1701)*, 2009.
- Morales G., Pérez S. y Mora J. “Estrategia de re-entrenamiento de redes neuronales para mejorar el control de la excitación de una máquina síncrona”. *Revista Scientia et Técnica (ISSN 0122-1701)*, Vol. 32, pp. 37–42, diciembre 2006.
- Morales G., Vargas H. y Mora J. “Concepto de zonas para localizar fallas en sistemas de distribución por medio de una herramienta de inteligencia artificial clasificadora”. *Proc. III Congreso Internacional de Ingenierías Eléctrica y Electrónica. IEEE Branch*, Bogotá, Colombia. marzo 2007.
- Park J.-W., Harley R. G. y Venayagamoorthy G. K. “Comparison of MLP and RBF Neural-Networks Using Deviation Signals for On-line Identification of a Synchronous Generator”. *Proceedings of the 2002 International Joint Conference on Neural Networks*, Honolulu, HI, USA. 2002.
- Park J.-W., Venayagamoorthy G. K. y Harley R. G. “MLP/RBF Neural-Networks-Based Online Global Model Identification of Synchronous Generator”. *IEEE TRANSACTIONS ON INDUSTRIAL ELECTRONICS*, VOL. 52, NO. 6, 2005.
- Pavella M., Ernest D. y Ruiz-Vega D. “Transient stability of power systems: a unified approach to assessment and control”. *Boston: Kluwer academic Publishers*, 2000.
- Pilluta S. y Keyhani A. “Neural Network Based saturation model for round rotor synchronous generator”. *IEEE TRANSACTIONS ON ENERGY CONVERSION*, VOL. 14, NO. 4, 1999.

- Ravan M., Dallirooy-Fard R. y Karrari M. “Synchronous Generator Black-Box Identification Using Continuous Wavelet Networks”. *Bulk Power System Dynamics and Control*, Cortina d’Ampezzo, Italy.
- S. Russell P. N. *Artificial intelligence: A modern approach*. Second Edition, Prentice Hall, 2002.
- Sierra C. R. *Herramienta software para el modelado y simulación de sistemas de eléctricos de potencia ante grandes perturbaciones: diseno y elaboración*. Tesis de grado, Escuela de Ingenierías Eléctrica, Electrónica y Telecomunicaciones, Universidad Industrial de Santander, 2003.
- Sierra C. R. *Herramienta software para el modelado y simulación de sistemas de eléctricos de potencia ante grandes perturbaciones*. Tesis de maestría, Escuela de Ingenierías Eléctrica, Electrónica y Telecomunicaciones, Universidad Industrial de Santander, 2007.
- Teeuwsen S. P., Erlich I. y El-Sharkawi M. A. “Advanced Method for Small-Signal Stability Assessment based on Neuronal Networks”. *IEEE PowerTech, Budapest*, 2004.
- Tsai H. y Keyhani A. “Development of a Neural Network Based Saturation Model For Synchronous Generator Analysis”. *IEEE Transactions on Energy Conversion*, Vol. 10, No. 4, 1995.
- Vittal V., Sauer P., Meliopoulos S. y Stefopoulos G. *On-line Transient Stability Assessment Scoping Study*. Power System Engineering Research Center, 2005.
- Wang X., Zhang T. y Xiao J. *Ship Synchronous Generator Modeling Based on RST and RBF Neural Networks*. Springer Berlin / Heidelberg, 2006.
- Wei-Feng S. y Shi-Long X. “A Novel Chaotic Neural Networks and Application”. *Proceedings of the Fourth International Conference on Machine Learning and Cybernetics, Guangzhou, 18-21*, 2005.
- Wright S. H. “Determination of Synchronous Machine Constants by Test”. *IEEE Trans*, Vol. 50, pp. 1331–1351, December 1931.
- Ye S., Zheng Y. y Qian Q. *Transient Stability Assessment of Power System Based on Support Vector Machine*. School of Electrical Engineering, Southwest Jiaotong University, 2006.
- yuen Chow M. y Thomas R. “Neural network synchronous machine modeling”. *IEEE TRANSACTIONS ON INDUSTRIAL ELECTRONICS* pp 1245-1253, 1989.