

**DISEÑO DE UN CONTROLADOR ÓPTIMO USANDO REDES
NEURONALES DINÁMICAS PARA UN SISTEMA DE GENERACIÓN
EÓLICA**

**JANER ANDRÉS RUIZ MARTÍNEZ
CRISTIAN GERARDO AGUIRRE ALVAREZ**

**UNIVERSIDAD TECNOLÓGICA DE PEREIRA
FACULTAD DE INGENIERIAS
PROGRAMA DE INGENIERÍA ELÉCTRICA
PEREIRA
2015**

**DISEÑO DE UN CONTROLADOR ÓPTIMO USANDO REDES
NEURONALES DINÁMICAS PARA UN SISTEMA DE GENERACIÓN
EÓLICA**

JANER ANDRÉS RUIZ MARTÍNEZ

Código 1059905785

CRISTIAN GERARDO AGUIRRE ALVAREZ

Código 1085278682

**Trabajo de grado presentado como requisito para optar al título de
Ingeniero Electricista**

Director

Ph.D. EDUARDO GIRALDO SUÁREZ

**UNIVERSIDAD TECNOLÓGICA DE PEREIRA
FACULTAD DE INGENIERIAS
PROGRAMA DE INGENIERÍA ELÉCTRICA
PEREIRA
2015**

Nota de aceptación:

Presidente del Jurado

Jurado 1

AGRADECIMIENTOS

Dedico de manera especial a mi hermana Lorena Aguirre, pues ella fue el principal cimiento para la construcción de mi vida profesional, sentó en mí las bases de responsabilidad y deseos de superación.

A mi familia por creer en mí y por brindarme su apoyo incondicional siempre.

CRISTIAN GERARDO AGUIRRE ALVAREZ

A mis padres, mi hermano y mi tío quienes con su dedicación y esfuerzo durante toda mi formación como profesional y vida han hecho posible este logro.

A cada uno de los miembros de mi familia quienes con paciencia y comprensión han sido parte decisiva en mi vida, en mi formación como persona y como profesional.

A mi querida Luisa Daniela Hidrobo que durante estos últimos años me ha apoyado y ha sido incondicional.

JANER ANDRÉS RUIZ MARTÍNEZ

A nuestro director de trabajo de grado Eduardo Giraldo por su paciencia y tiempo dedicado para la realización de este proyecto.

A los compañeros y amigos por hacer de esta etapa la mejor experiencia de la vida.

CONTENIDO

1. MODELO MATEMÁTICO DE LA TURBINA EÓLICA	1
1.1. Modelo mecánico de la turbina	2
1.2. Modelado del viento	4
1.2.1. Velocidad básica del viento	5
1.2.2. Velocidad de ráfaga	5
1.2.3. Velocidad gradual del viento	5
1.2.4. Componente de ruido de la velocidad del viento	6
2. ESTUDIO Y MODELADO DEL GENERADOR DE INDUCCIÓN	7
2.1. Aspecto constructivo	7
2.1.1. Par inducido en un motor de inducción	8
2.1.2. Deslizamiento del rotor	10
2.1.3. Circuito equivalente del motor de inducción	11
2.2. Generador de inducción	12
2.2.1. Modelo del SCIG	12
3. CONTROL PI EN LA TURBINA	18
3.1. Controlador PI del sistema eólico	18
4. CONTROL ÓPTIMO USANDO REDES NEURONALES	21
4.1. Control óptimo	21
4.1.1. Algoritmo de optimización de Levenberg - Marquardt	21
4.2. Redes neuronales artificiales	24
4.2.1. Tipos de Función de Activación	26
4.2.2. Características de una Red Neuronal Artificial	28
4.2.3. Principales tipos de redes neuronales	29
5. SIMULACIÓN Y ANÁLISIS DE RESULTADOS	37
5.1. Modelo de la Red neuronal	37
5.2. Simulación	38
5.3. Resultados.	43
5.4. Análisis de resultados.	44
6. CONCLUSIONES, RECOMENDACIONES y TRABAJOS FUTUROS	46
6.1. Conclusiones.	46
6.2. Recomendaciones.	46

6.3. Trabajos futuros.	47
--------------------------------	----

ÍNDICE DE FIGURAS

1.1. Turbina	1
1.2. Varición de C_p de la turbina eólico en función de θ y λ	3
1.3. Característica de seguimiento de la turbina del punto máximo de potencia	4
2.1. Máquina de inducción	8
2.2. Par de inducción	9
2.3. Circuito equivalente por fase de un motor de inducción	11
2.4. Par-velocidad de una máquina de inducción	12
2.5. Ejes de transformación dq.	14
2.6. Modelo del generador de inducción en el eje dq.	16
3.1. Diagrama de bloques del controlador proporcional integral	18
3.2. Esquema del convertidor Back-to-Back	19
3.3. Sistema de control al lado del red	19
3.4. Regulador de V_{DC} con control PI	20
4.1. Neurona bilógica a la neurona artificial	24
4.2. Esquema de funcionamiento de una neurona artificial	24
4.3. Esquema de la arquitectura de una red	26
4.4. Función de Activación de Escalón simétrica	26
4.5. Función de Activación Lineal (Purelin)	27
4.6. Función de Activación Sigmoidal	28
4.7. Funciones de Activación	28
4.8. Perceptrón Simple	30
4.9. Perceptrón Multicapa	31
4.10. Esquema del modelo Backpropagation	32
4.11. Una sola neurona oculta conectada con la neurona de la capa de salida	33
4.12. Red Adaline	34
5.1. Regulador de V_{DC} con control de modelo de referencia	37
5.2. Arquitectura del controlador de modelo de referencia	38
5.3. Estructura de la red neuronal	39
5.4. Entrada y salida de la planta	39
5.5. Progreso del entrenamiento de la red	40
5.6. Rendimiento de la red	41
5.7. Función de transferencia	41
5.8. Entrada y salida del modelo de referencia	42

5.9. Respuesta de la planta por las redes neuronales del control del modelo de referencia	42
5.10. Señal de V_{DC} con controlador PI	43
5.11. Señal de V_{DC} con controlador óptimo usando RND	43
5.12. Señal de Potencia Activa con controlador PI	43
5.13. Señal de Potencia Activa con controlador óptimo usando RND	44
5.14. Señal de Corriente de eje directo con controlador PI	44
5.15. Señal de Corriente de eje directo con controlador óptimo usando RND	44

RESUMEN

En los últimos años se ha observado un gran incremento en la generación de energía eléctrica procedente de la energía eólica, que es una de las fuentes de energía renovable con mayor aplicación. Estos proyectos relacionados con energía proveniente del viento se pueden envolver en proyectos de parques eólicos para la interconexión con el sistema eléctrico de potencia.

En este proyecto de grado se implementa un sistema de generación eólica conectado al sistema eléctrico de potencia usando Simulink. Un parque eólico suministra 9 MW generados por seis turbinas de viento de 1.5 MW. Las turbinas de viento utilizan un generador de inducción de jaula de ardilla (SCIG por sus siglas en inglés) y un convertidor back-to-back. El método de conexión del SCIG permite extraer la máxima energía del viento a bajas velocidades de viento y reducir al mínimo las tensiones mecánicas en la turbina durante las ráfagas de viento. Este documento muestra un estudio en el estado del arte sobre los modelos matemáticos de la turbina eólica y el SCIG; conjuntamente nombrar aspectos importantes de los métodos de control convencional PI y control óptimo usando redes neuronales dinámicas (RND) aplicados al regulador de voltaje DC (V_{DC}).

Para el desarrollo de este trabajo fue necesario identificar un sistema dinámico, tal identificación se realizó tomando datos de entrada y de salida de la planta a identificar, luego de esto se aplicó un modelo de control óptimo usando RND para el sistema, la técnica de control implementada sobre las variables de interés, se hizo de forma desacoplada. El objetivo de utilizar un controlador óptimo usando RND fue para hacer una comparación con el controlador convencional PI y además observar el desempeño de cada uno de estos tipos de control a diferentes velocidades de viento.

INTRODUCCIÓN

La demanda de Energía Eléctrica ha ido en aumento al pasar los años, teniendo en cuenta de que este puede llegar a ser un proceso costoso y contaminante, debido a esto se busca generar alternativas que sean eficientes, que a su vez reduzcan el impacto en el medio ambiente, estas alternativas son las Energías Renovables.

La generación de energía eléctrica a partir del viento resulta ser una de las formas más atractivas entre las energías renovables para generar electricidad, debido que a su materia prima, es el viento. Hay que tener en cuenta que la utilización del viento como fuente primaria de producción de la energía eléctrica puede presentar problemas debido a la variación del viento, ya que al momento de conectar la turbina eólica al generador de inducción, éste se limita debido a las fluctuación del viento, lo que no permite que el generador tenga un comportamiento óptimo en términos de eficacia. Por lo mencionado anteriormente en los sistemas eléctricos de potencia en los últimos años se han utilizado generadores de inducción conectados al red mediante un sistema electrónico de potencia back-to-back (por su nombre en inglés) el cual permite tener una regulación de voltaje de enlace DC (V_{DC}) [1].

El desarrollo de la tecnología en los últimos años, ha seguido un proceso de optimización y mejora de los diseños en los sistemas de generación eólico, la explotación óptima de este sistema es muy complejo dado a la naturaleza del viento. Debido a esto, se requiere de métodos avanzados de sistemas de control óptimo [2]. Estos métodos de control avanzados pueden ser utilizados para diferentes disciplinas como: procesos industriales, control de plantas de generación de energía, sistemas eléctricos, mecánicos. Es importante investigar nuevos métodos de control, ya que en sistemas multivariables es difícil diseñar los controladores cuando el número de variables es muy grande, lo anterior se puede resolver a partir de sistemas en cascada (caso de los PI), o con sistemas inteligentes como son las redes neuronales, lógica difusa, entre otros tipos de control.

En busca de un sistema de control óptimo el cual pretende obtener la mayor cantidad de potencia a partir del viento y su estabilidad en un corto tiempo, se aplicará en este proyecto técnicas de control óptimo con sistemas inteligentes como son las redes neuronales dinámicas (RND) [3].

Las RND es una técnica eficaz para resolver muchos problemas del mundo real, tienen la capacidad de aprender de la experiencia con el fin de mejorar su rendimiento y adaptarse

a los cambios ambientales. Además son capaces de tratar con información incompleta o datos de ruido.

Justificación

El progresivo agotamiento de los combustibles fósiles y su encarecimiento unido al cambio climático, además de la creciente demanda energética ha motivado la investigación en fuentes de energías alternativas confiables y limpias. La energía Eólica representa una de las alternativas más viables para la generación de energía eléctrica, pues los avances tecnológicos en aéreas como control óptimo y electrónica de potencia nos permiten convertir el viento en electricidad de una manera eficiente, confiable y económica [4].

Son diversos los sistemas involucrados en el proceso de transformación de energía que se produce desde la incidencia del viento sobre el aerogenerador hasta su posterior conversión en energía eléctrica. Existe una transformación aerodinámica que convierte la energía cinética del viento en energía mecánica en un eje, que en este caso acciona un generador de inducción de jaula de ardilla (SCIG). El regulador de voltaje V_{DC} se controlará con el convertidor back-to-back, específicamente el de al lado de la red, esto para que en definitiva, se pueda extraer la máxima energía del viento.

En el sistema de generación eólica, el sistema de velocidad variable de generación es más atractivo que el sistema de velocidad fija debido a la mejora en la producción de energía eólica, las redes neuronales dinámicas brindan mayor flexibilidad ante velocidades variables producidas por diversas condiciones de viento, aprovechando la característica de este sistema se propone obtener la máxima eficiencia en las distintas velocidades de viento por medio de un control optimizando [5].

Los controladores clásicos PI son aplicados en sistemas físicos lineales dado que en ellos es posible realizar un análisis en el dominio de la frecuencia; Por su parte el controlador óptimo basado en RND propuesto en este trabajo , es aplicable a sistemas no lineales y sistemas dinámicos, por esto es necesario hacer una análisis comparativo entre estos tipos de controladores ,los cuales son aplicables a un sistema de generación eólico con un SCIG y convertidor back-to- back.

Objetivos

Objetivo general.

Diseñar un controlador óptimo usando redes neuronales dinámicas para un sistema de generación eólica basado en un generador de inducción de jaula de ardilla y un convertidor espalda con espalda (back-to-back).

Objetivos específicos

- Modelar el sistema de generación eólica basado en un SCIG y un convertidor back-to-back.
- Diseñar un sistema de control óptimo basado en redes neuronales dinámicas para sistemas multivariables.
- Hacer un análisis comparativo de la técnica propuesta sobre el sistema de generación eólica y un modelo de control clásico basado en PI.

CAPÍTULO 1

MODELO MATEMÁTICO DE LA TURBINA EÓLICA

Un aerogenerador o turbina eólica es fundamentalmente un dispositivo que genera energía eléctrica a partir de energía eólica. Generalmente está formado por un generador eléctrico vinculado mecánicamente a una hélice que es impulsada por el viento. Esta hélice convierte parte de la energía cinética del viento en energía mecánica de rotación, que es luego convertida en energía eléctrica a través del generador. La energía eléctrica puede luego ser entregada a la red o ser utilizada para alimentar algún sistema aislado, generalmente en combinación con otras fuentes, conformando sistemas híbridos de generación. Actualmente, la mayoría de los aerogeneradores que se construyen son de eje horizontal con dos o tres palas, por cuestiones de eficiencia, costo, comportamiento mecánico.

En la Figura 1 se indica las principales partes que conforman un aerogenerador de eje horizontal. En la imagen se muestra de una manera amplificada la góndola para detallar los elementos que se encuentran en su interior. La góndola donde se encuentra el generador y la hélice se ubican en la parte superior de la torre, que ésta debe ser capaz de soportar el peso de los dispositivos que sostiene como también las grandes cargas estáticas generadas por el viento sobre las palas.




Figura 1.1. Turbina

Dependiendo de la orientación de la turbina con respecto a la dirección que sopla el viento y del perfil que estén las palas al paso del mismo se puede extraer una gran

cantidad de energía; se cuenta generalmente con varios sistemas que controlan estos aspectos. El sistema de orientación mostrado en la figura 1.1 es el encargado de rotar el conjunto formado por la góndola y la hélice, ubicándolo de frente al viento. Por otro lado, en el buje puede disponerse de motores que permiten cambiar el ángulo de paso de las palas, es decir, que permite rotarlas sobre sus ejes para cambiar el ángulo con el que enfrentan al viento [6].

Un aerogenerador necesita una velocidad mínima de viento (velocidad de acoplamiento o cut-in) de 3-5 m/s y entrega potencia nominal a una velocidad de 12-14 m/s. Por razones de seguridad, se activa el frenado de la turbina a velocidades por lo general superiores a 25 m/s (velocidad de desconexión o cut-off). El bloqueo puede efectuarse por medio de frenos mecánicos que detienen el rotor o en el caso de las palas de inclinación variable, escondiéndolas del viento al ponerlas en la posición conocida como bandera [6]. Por último se debe mencionar en una breve descripción la caja multiplicadora, que puede estar incluida o no ser necesaria en el sistema, según el tipo de generador y configuración empleados. La caja multiplicadora permite aumentar las bajas velocidades de rotación de las palas, llevándolas al rango de trabajo del generador.

1.1. Modelo mecánico de la turbina

De la expresión de energía cinética del flujo de aire, la potencia contenida en el viento que pasa por un área A con velocidad del viento v_1 [7]:

$$P_w = \frac{\rho}{2} A v_1^3, \quad (1.1)$$

Donde ρ es la masa específica del aire que depende de la presión del aire y de la humedad, se supone $\rho \approx 1.2 \frac{kg}{m^3}$. Las corrientes de aire tienen dirección axial a través de la turbina eólica, de lo que A es el área de barrida circular. La potencia útil obtenida se expresa por medio del coeficiente de potencia C_p [7]

$$P_w = C_p \frac{\rho}{2} A v_1^3 \quad (1.2)$$

Se han hecho aproximaciones matemáticas para conocer el valor del coeficiente de potencia C_p . Si la turbina fuera a extraer toda la energía cinética del viento esto significaría que la velocidad del viento detrás de la turbina es cero. Esto no es posible ya que el flujo de aire debe ser continuo, de modo que la energía máxima teórica que se puede extraer es con $C_p = 0,59$ y se denomina el límite de Betz:

$$C_p = 0.22 \left(\frac{116}{\beta} - 0.4\theta - 5 \right) e^{-\frac{12.5}{\beta}} \quad (1.3)$$

Donde β se calcula con la siguiente ecuación [8]:

$$\beta = \frac{1}{\frac{1}{\lambda + 0.08\theta} - \frac{0.035}{\theta^3 + 1}} \quad (1.4)$$

Donde θ y λ es el ángulo de paso y la velocidad específica, respectivamente.




Figura 1.2. Variación de C_p de la turbina eólico en función de θ y λ

Para obtener la máxima potencia extraída del viento en función de θ y λ se tiene la ecuación 1.5. De acuerdo a la figura 1.2 se puede observar que a medida que aumenta el ángulo de paso θ el coeficiente de potencia C_p disminuye:

$$P_t = \frac{1}{2} \rho \pi R^2 C_p(\theta, \lambda) v_1^3 \quad (1.5)$$

Conocido P_t , se puede obtener el torque de la turbina T_r y la velocidad angular de la turbina ω_t :

$$\omega_t = \frac{\lambda v_1}{R} \quad (1.6a)$$

$$T_t = \frac{P_t}{\omega_t} \quad (1.6b)$$

Para obtener una ecuación más compleja para hallar el torque de la turbina en función de θ y λ se obtiene a partir de reemplazar la ecuación (1.6b) en la ecuación (1.5) y luego en (1.6a):

$$T_t = \frac{1}{2} \rho \pi R^3 C_t(\lambda, \beta) v_1^2 \quad (1.7)$$

Donde C_t es igual a :

$$C_t = \frac{C_p(\theta, \beta)}{\lambda} \quad (1.8)$$

La curva de C_p con la curva del punto máximo de potencia se puede ver en la figura 1.3, lo que se puede observar que para cualquier velocidad de viento, hay una velocidad ω_r que genera la potencia máxima extraída P_t .

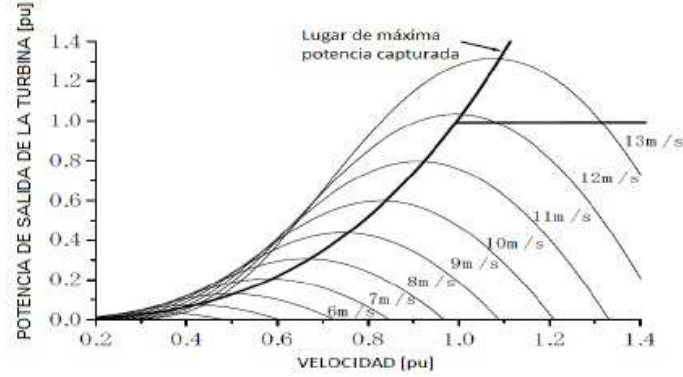


Figura 1.3. Característica de seguimiento de la turbina del punto máximo de potencia

El modelo matemático del tren de transmisión difiere dependiendo de la complejidad del estudio que se realice, por ejemplo, cuando se estudia problemas como fatiga torsional, las dinámicas de todo el sistema tienen que ser incluidas. Sin embargo, cuando el estudio se centra en la interacción entre los parques eólicos y las redes eléctricas, el tren de transmisión puede ser tratado como un modelo agrupado de masas en aras de la eficiencia del tiempo y precisión aceptable. La ecuación muestra el modelo matemático del tren de transmisión.

$$\frac{dW_g}{dt} = \frac{T_e - T_{WG}}{J_{eq}} - \frac{B_m}{J_{eq}} \cdot W_g \quad (1.9)$$

Donde el subíndice g representa los parámetros del lado del generador, W_g es la velocidad angular mecánica [rad/s] del generador, B_m es el coeficiente de amortiguamiento [N.m/s], T_e es el torque electromecánico [N.m], T_{WG} es el torque aerodinámico que ha sido transferido al lado del generador y J_{eq} es la inercia rotacional equivalente de la generador [kg.m²], que se deriva a partir de la ecuación. Donde J_g y J_W ; son las inercias del generador y del rotor [kg.m²], respectivamente.

$$J_{eq} = J_g + \frac{J_W}{n_g^2} \quad (1.10)$$

1.2. Modelado del viento

Se necesita un modelo que puede simular correctamente el efecto espacial del comportamiento del viento, incluyendo la velocidad de ráfagas, los cambios graduales

de la velocidad del viento (rampa) y el ruido de fondo. La velocidad del viento se modela como la suma de los cuatro componentes que se pueden observar en la ecuación:

$$V_w = V_{wb} + V_{wg} + V_{wr} + V_{wn}, \quad (1.11)$$

donde V_{wb} es la velocidad básica del viento, V_{wg} es la velocidad de ráfaga, V_{wr} representa los cambios rápidos en la velocidad del viento y V_{wn} es la componente del ruido; todas las componentes son medidas en [m/s].

1.2.1. Velocidad básica del viento

La velocidad básica del viento está relacionada con la velocidad media anual del viento (MAWS, por sus siglas en ingles); ya que esta determina una velocidad promedio para un sitio en específico y muestra las horas en el año que se produce la velocidad promediada, la MAWS se calcula a partir de datos estadísticos medidos a lo largo del año.

A partir del MAWS se puede calcular la distribución del viento utilizando la distribución de Rayleigh la cual es un caso especial de la distribución de Weibull, donde el factor de escala de la distribución de Weibull se vincula a la MAWS. La distribución de Rayleigh se observa en la ecuación.

$$F(v) = \exp \left[-\frac{\pi}{4} \left(\frac{v}{v_{mean}} \right)^2 \right] \quad (1.12)$$

Donde v es la velocidad medida y v_{mean} es la misma MAWS.

1.2.2. Velocidad de ráfaga

Velocidad de ráfaga del viento puede simular la variación de la velocidad del viento en un corto tiempo. La velocidad de ráfaga está dada por:

$$V_{Wg} = \begin{cases} 0 & t < T_{1g} \\ \frac{G_{max}}{2} \left[1 - \cos \left(2\pi \frac{t-T_{1g}}{T_{1g}} \right) \right] & T_{1g} < t < T_{1g} + T_g \end{cases} \quad (1.13)$$

Donde G_{max} es el valor máximo de la velocidad de ráfaga, T_{1g} es el tiempo de en qué inicia la ráfaga y T_g es el periodo de ráfaga.

1.2.3. Velocidad gradual del viento

La velocidad gradual del viento puede simular la variación de la velocidad del viento en un largo tiempo. La velocidad gradual viento está dada por:

$$V_{Wr} = \begin{cases} 0 & t < T_{1r} \\ R_{max} \cdot \frac{t-T_{1r}}{T_{2r}-T_{1r}} & T_{1r} < t \leq T_{1r} + T_r \\ R_{max} & t < T_{2r} \end{cases} \quad (1.14)$$

Donde R_{max} es el valor máximo de la velocidad gradual del viento, T_{1r} es el momento en que aparece el tiempo gradual y T_{2r} es el tiempo en el que se acabe el viento gradual y T_r es el tiempo que dura el viento gradual.

1.2.4. Componente de ruido de la velocidad del viento

La componente de ruido de la velocidad del viento refleja el carácter aleatorio de la velocidad del viento. Se obtiene por las siguientes ecuaciones:

$$V_{Wn} = 2 \sum_{i=1}^n [Sv(w_i)\Delta w]^{\frac{1}{2}} \cos(w_i t + \varphi_i) \quad (1.15)$$

$$Sv(w_i) = \frac{2K_N F^2 w_i}{\pi^2 \left[1 + \left(\frac{F w_i}{\mu \pi} \right)^2 \right]} \quad (1.16)$$

$$w_i = (i - 0.5)\Delta w \quad (1.17)$$

Donde φ_i es la tolerancia estocástica con distribución uniforme, K_N es el coeficiente de rugosidad de la superficie, F es la amplitud de la componente de ruido de la velocidad del viento, w_i es la frecuencia circular de la componente i -ésima y $Sv(w_i)$ es la amplitud del componente de ruido i -ésima. [9]

CAPÍTULO 2

ESTUDIO Y MODELADO DEL GENERADOR DE INDUCCIÓN

Principalmente existen dos máquinas eléctricas de corriente alterna: Las máquinas síncronas y las asíncronas o de inducción, estas máquinas eléctricas pueden trabajar como motor y generador. Las máquinas síncronas cuya corriente de campo magnético es suministrado por una fuente externa de corriente directa; mientras que las de inducción cuya corriente de campo magnético se suministra por inducción magnética en sus devanados de campo.

Uno de los fundamentos de la máquina AC es que por los devanados de la armadura circula unas corrientes trifásicas de igual magnitud desfasados 120° , esto produce un campo magnético giratorio de magnitud constante. Este campo magnético rotatorio que es creado por los conductores del rotor e induce a los devanados de la armadura, del estator, unas tensiones trifásicas.

Recíprocamente, un sistema de corrientes trifásicas que circulan por el arrollamiento de la armadura produce un campo magnético giratorio, el cual interactúa con el campo magnético del rotor y se produce un par en el eje de la máquina. Estos dos efectos corresponden, a la acción generadora y motora, respectivamente.[10] Los generadores síncronos no se utilizan normalmente con turbinas eólicas, ya que el generador funciona a una velocidad constante y la velocidad de viento es variable.

A su pequeño tamaño por KW de potencia de salida, los generadores de inducción son muy favorables para los sistemas eólicos, además que es robusta, de bajo costo y requiere poco mantenimiento, motivo por el cual se considera apropiada para operar en lugares aislados.

2.1. Aspecto constructivo

La máquina asíncrona o de inducción está formada por un rotor y un estator, ver figura 2.1. El rotor es el inducido y las corrientes que circulan por él aparecen de la interacción con el flujo del estator, estas máquinas se pueden clasificar según el tipo de rotor:

- **Rotor en jaula de ardilla:** el rotor está en cortocircuito, está constituido por una serie de barras conductoras en paralelo cortocircuitadas mediante anillos circulares, ver figura 2.1.
- **Rotor devanado:** los devanados se conectan en estrella, en las máquinas trifásicas. El extremo de cada uno de los devanados de fase se conecta a anillos rozantes que están asilados del eje del rotor, ver figura 2.1, [10].




Figura 2.1. Máquina de inducción

2.1.1. Par inducido en un motor de inducción

En la figura 2.2 muestra un motor de inducción de jaula de ardilla, Si se aplica al estator un sistema trifásico de voltajes, por sus devanados circula un sistema trifásico de corrientes.

Estas corrientes producen un campo magnético \mathbf{B}_s , que rota en sentido contrario a las manecillas del reloj. Esta velocidad de rotación está dada por:

$$n_{sinc} = \frac{120f_e}{P} \quad (2.1)$$

Donde f_e es la frecuencia del sistema en Hz, P es el número de polos y n_{sinc} es la velocidad de rotación del campo magnético en rpm o velocidad síncrona. Este campo magnético rotacional \mathbf{B}_s pasa sobre las barras del rotor e induce voltaje en ellas, el voltaje inducido en una barra determinada del rotor está dada por la ecuación: [11]

$$e_{ind} = (\mathbf{v} \times \mathbf{B}) \cdot \mathbf{l}, \quad (2.2)$$

donde:

v = velocidad de la barra, relativa al campo magnético.

B = vector de densidad de flujo magnético.

l = longitud del conductor en el campo magnético.

Este voltaje inducido, genera una corriente que circula por los devanados del rotor y la corriente de los devanados del rotor produce un campo magnético B_R . La interacción de estos campos magnéticos produce el par electromagnético de la máquina, este par está dado por: [10]

$$\tau_{ind} = k B_R \times B_s \quad (2.3)$$

Donde K es una constante que depende de la construcción de la máquina. La dirección del par resultante va en sentido contrario de las manecillas del reloj; debido a que la dirección del par inducido por el rotor va en sentido contrario a las macillas del reloj. El rotor se acelera en esta dirección.




Figura 2.2. Par de inducción

Par de inducido en un motor de inducción. a) El campo rotacional del estator B_s induce voltaje en las barras del rotor; b) El voltaje del rotor produce un flujo de

corriente en el rotor que atrasa el voltaje debido a la inductancia del mismo; c) La corriente del rotor produce un campo magnético en el rotor \mathbf{B}_R que está a 90° detrás de ella y \mathbf{B}_R interactúa con \mathbf{B}_{net} para producir en la máquina un par en sentido contrario a las manecillas del reloj[11].

Sin embargo, la velocidad del motor tiene un límite finito. Si el rotor del motor de inducción estuviera rotando a velocidad síncrona, las barras del rotor serían estacionarias con respecto al campo magnético y no habría voltaje inducido. Si e_{ind} fuera igual a 0, no habría corriente en el rotor ni tampoco campo magnético rotatorio. Sin campo magnético el par inducido sería cero y el rotor por fricción se frenaría. En conclusión el motor de inducción puede girar a velocidades cercanas a la velocidad síncrona, pero nunca alcanzará a la velocidad síncrona.[11]

2.1.2. Deslizamiento del rotor

El voltaje inducido en los devanados del rotor depende de la velocidad del rotor con respecto a los campos magnéticos. Como el comportamiento de la máquina de inducción depende de los voltajes y las corrientes del rotor, es útil hablar en términos de la velocidad relativa entre el rotor y el campo magnético. En general se utiliza dos términos para definir el movimiento relativo. Uno de ellos es la velocidad de deslizamiento, definida con la siguiente ecuación [11].

$$n_{des} = n_{sinc} - n_m, \quad (2.4)$$

donde

n_{des} = Velocidad de deslizamiento de la máquina.

n_{sinc} = Velocidad de los campos magnéticos.

n_m = Velocidad mecánica del eje del motor.

El otro término es el desplazamiento, el cual es la velocidad relativa expresada sobre una base en por unidad o en porcentaje, está definido como: [11]

$$s = \frac{n_{des}}{n_{sinc}} (100 \%) = \frac{n_{sinc} - n_m}{n_{sinc}} (100 \%) \quad (2.5)$$

Esta ecuación también se puede expresar en términos de la velocidad angular ω (radianes por segundo):

$$s = \frac{\omega_{des}}{\omega_{sinc}} (100 \%) = \frac{\omega_{sinc} - \omega_m}{\omega_{sinc}} (100 \%) \quad (2.6)$$

Se puede expresar la velocidad mecánica del eje del rotor en función de la velocidad síncrona y el deslizamiento como:

$$\omega_m = (1 - s) \omega_{sinc} \quad (2.7)$$

la frecuencia del motor es directamente proporcional a la diferencia de la velocidad del campo magnético del estator ω_{sinc} y la velocidad del rotor ω_m . La frecuencia del rotor esta dada por: [10]

$$f_r = s f_e \quad (2.8)$$

2.1.3. Circuito equivalente del motor de inducción

Los principales aspectos que se deben tener en cuenta para la construcción del modelo son:

1. **Pérdidas en el cobre:** son pérdidas por calentamiento resistivo en los devanados del estator y rotor.
2. **Pérdidas por corrientes parásitas:** son pérdidas por calentamiento resistivo en el núcleo del estator, son proporcionales al cuadrado del voltaje aplicado al motor.
3. **Flujo disperso:** son los flujos que escapan del núcleo y del rotor y pasan únicamente a través de uno de los devanados del estator.
4. **Pérdidas por histéresis:** están relacionadas con los reordenamientos de los dominios magnéticos en el núcleo durante cada semiciclo.




Figura 2.3. Circuito equivalente por fase de un motor de inducción

En la figura 2.3 se observa el circuito equivalente del motor de inducción, r_r , r_s se modelan como las pérdidas en el cobre, donde r_r , r_s son pérdidas resistivas tanto en el rotor como en el estator, respectivamente. El flujo disperso es modelado por una inductancia en el rotor y otra en el estator, la corriente de magnetización se modela por una reactancia X_M . Las pérdidas en el núcleo debidas al fenómeno de histéresis y corrientes parásitas, se modelan por una resistencia R_C .

En la práctica es más recomendable referir el modelo del rotor al estator, así como se muestra en la figura 2.3

2.2. Generador de inducción

En la figura 2.4, muestra la curva de par-velocidad de la máquina de inducción. Si una máquina asíncrona se impulsa a una velocidad superior a la síncrona n_{sinc} , es decir, un deslizamiento negativo, el motor recibe potencia mecánica en lugar de entregarla y así operaría con un generador.

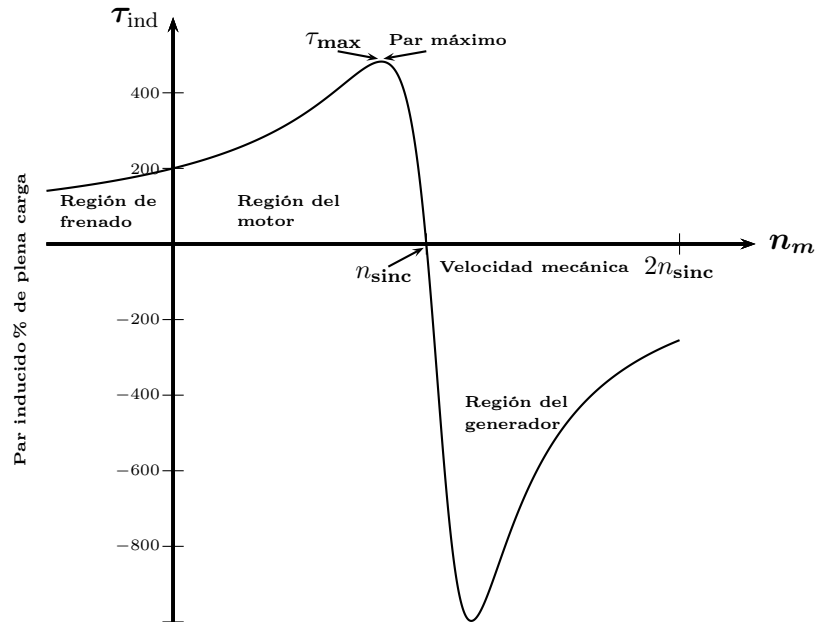


Figura 2.4. Par-velocidad de una máquina de inducción

El generador de inducción no posee un circuito de campo separado, por esta razón no puede producir potencia reactiva, de hecho, consume potencia reactiva y para mantener el campo magnético del estator necesita estar permanentemente conectado a una fuente de potencia reactiva externa, esta fuente también debe de controlar el voltaje en terminales del generador.

2.2.1. Modelo del SCIG

Transformada dq

Uno de los problemas comunes en la ingeniería es modelar las máquinas eléctricas. Las ecuaciones diferenciales son muy complejas ya que dependen de la posición relativa del rotor con respecto al estator. Por ello, para la solución de este problema se suelen emplear cambios de variables que las simplifiquen. Una de esas transformaciones es la conocida como transformada dq.

Mediante la transformación en coordenadas dq, a partir de un sistema trifásico, ya sea de tensiones, intensidades o flujos, puesto sobre un sistema de ejes abc que forman 120° , se obtiene un sistema equivalente de tensión, intensidad o flujo, asociado a unos ejes que forman 90° , llamados dq, que giran a una determinada velocidad. En esta transformación se pueden derivar sistemas de ecuaciones más sencillos para los elementos como la máquina de inducción. Para obtener las componentes dq se proyectan las componentes v_a , v_b y v_c sobre los ejes dq. Se pueden obtener mediante la siguiente expresión matricial.[12]

$$\begin{bmatrix} v_d \\ v_q \\ v_0 \end{bmatrix} = \mathbf{k} \begin{bmatrix} v_a \\ v_b \\ v_c \end{bmatrix} \Leftrightarrow \mathbf{V}_{dq0} = \mathbf{kV}_{abc} \quad (2.9)$$

Donde v_a , v_b , v_c : es conjunto de señales trifásicas situadas sobre los ejes a, b y c, respectivamente; v_q y v_d representan las componentes a, b y c proyectadas sobre los ejes d y q respectivamente; v_0 es el valor medio el de las componentes a, b y c, llamada componente de secuencia cero.

\mathbf{k} es la matriz de transformación:

$$\mathbf{k} = \begin{bmatrix} \cos(\theta) & \cos(\theta - \frac{2\pi}{3}) & \cos(\theta + \frac{2\pi}{3}) \\ -\text{sen}(\theta) & -\text{sen}(\theta - \frac{2\pi}{3}) & -\text{sen}(\theta + \frac{2\pi}{3}) \\ \frac{1}{2} & \frac{1}{2} & \frac{1}{2} \end{bmatrix} \quad (2.10)$$

La variable θ representa el ángulo que forman los ejes dq elegidos con los abc. Dicho ángulo se puede poner en función de la velocidad de giro relativa ω de los ejes dq con respecto a los ejes abc:[12].




Figura 2.5. Ejes de transformación dq.

El ángulo θ que aparece en la ecuación anterior representa un ángulo eléctrico, lo mismo ocurre con la velocidad ω . Se representa con la siguiente ecuación:

$$\omega = p\omega_m \quad (2.11a)$$

$$\theta = p\theta_m \quad (2.11b)$$

En una máquina eléctrica, el ángulo que representa el desplazamiento entre los ejes eléctricos de rotor y estator, es igual al número de pares de polos p por el ángulo mecánico existente entre rotor y estator. Donde ω_m es la velocidad mecánica y θ_m es el ángulo mecánico, de forma que: $\omega_m = d\theta_m/dt$.

Para la transformación inversa, se emplean las expresiones:

$$\begin{bmatrix} v_a \\ v_b \\ v_c \end{bmatrix} = \mathbf{k}^{-1} \begin{bmatrix} v_d \\ v_q \\ v_0 \end{bmatrix} \Leftrightarrow \mathbf{V}_{abc} = \mathbf{k}^{-1} \mathbf{V}_{dq0}, \quad (2.12)$$

donde:

$$\mathbf{k}^{-1} = \begin{bmatrix} \cos(\theta) & -\text{sen}(\theta) & 1 \\ \cos(\theta - \frac{2\pi}{3}) & -\text{sen}(\theta - \frac{2\pi}{3}) & 1 \\ \cos(\theta - \frac{2\pi}{3}) & -\text{sen}(\theta - \frac{2\pi}{3}) & 1 \end{bmatrix} \quad (2.13)$$

En algunos libros existen unas transformaciones dq, las cuales aparecen en la siguiente tabla:

Velocidad de giro de las coordenadas de referencia	Interpretación	Variables dq	Ejes
ω	Variable del circuito estacionario referidas a un eje de coordenadas que gira a una velocidad arbitraria	V_d, V_q, V_0	$d-q$
0	Variable del circuito estacionario referidas a un eje de coordenadas que gira a una velocidad estacionaria (Clark)	V_d^s, V_q^s, V_0	d_s-q_s
ω_r	Variable del circuito estacionario referidas a un eje de coordenadas que gira con el rotor (Park)	V_d^r, V_q^r, V_0	d_r-q_r
ω_e	Variable del circuito estacionario referidas a un eje de coordenadas que gira a velocidad síncrona	V_d^s, V_q^s, V_0	d_s-q_s

Tabla 2.1. Sistemas de referencia

Para las corrientes del estator en un sistema de referencia a,b,c, como i_{sa}, i_{sb}, i_{sc} se puede representar en otro sistema de referencia mediante la tranformada de dq0, ver figur 2.5,[13].

El ángulo θ_s se define como el ángulo comprendido entre el eje magnético de la fase a (a lo largo de ese eje se sitúa el valor máximo del campo magnético de la fase a) y el eje horizontal del sistema de referencia a emplear, que es el eje α_s en el caso del sistema fijado al estator o el eje d en caso del sistema móvil, ver figura 2.5, [14].

El ángulo θ_s evoluciona respecto al tiempo de la siguiente manera:

$$\theta_s = \frac{d\theta_s}{dt} + \theta_s(t=0) = \omega_1 t + \theta_s(t=0). \quad (2.14)$$

El modelo del generador de inducción es muy similar al del motor de inducción. Las siguientes ecuaciones describen un generador de inducción de jaula de ardilla, en el marco de referencia dq.

$$v_{ds} = R_s i_{ds} + \omega \Psi_{qs} + \frac{d\Psi_{ds}}{dt}, \quad (2.15a)$$

$$v_{qs} = R_s i_{qs} + \omega \Psi_{ds} + \frac{d\Psi_{qs}}{dt}, \quad (2.15b)$$

$$v_{dr} = 0 = R_r i_{dr} + (\omega - \omega_r) \Psi_{qr} + \frac{d\Psi_{dr}}{dt}, \quad (2.15c)$$

$$v_{qr} = 0 = R_r i_{qr} + (\omega - \omega_r) \Psi_{dr} + \frac{d\Psi_{qr}}{dt}, \quad (2.15d)$$

donde v_{ds} , v_{qs} , v_{dr} , v_{qr} , R_s , R_r , L_m , Ψ_{ds} , Ψ_{qs} , Ψ_{dr} , Ψ_{qr} , i_{ds} , i_{qs} , i_{dr} , i_{qr} , ω y ω_r es el voltaje en el estator en eje directo, voltaje del estator en el eje de cuadratura, voltaje en el rotor en el eje directo, voltaje en el rotor en el eje de cuadratura, resistencia en el estator, resistencia en el rotor, inductancia mutua, enlace de flujo del estator en el eje directo, enlace de flujo del estator en el eje de cuadratura, enlace de flujo del rotor en el eje directo, enlace de flujo del rotor en el eje de cuadratura, corriente del estator en el eje directo, corriente del estator en el eje de cuadratura, corriente del rotor en el eje directo, corriente del rotor en el eje de cuadratura, marco de referencia de la velocidad angular y velocidad angular eléctrica del rotor, respectivamente. Ver figura 2.6 [15].




Figura 2.6. Modelo del generador de inducción en el eje dq.

Las corrientes del estator y rotor pueden ser expresadas en términos de los enlaces de flujo dq, como se muestra a continuación:

$$\begin{bmatrix} i_{ds} \\ i_{qs} \\ i_{dr} \\ i_{qr} \end{bmatrix} = \begin{bmatrix} -\frac{l_r}{l_\alpha} & 0 & \frac{l_m}{l_\alpha} & 0 \\ 0 & -\frac{l_r}{l_\alpha} & 0 & \frac{l_m}{l_\alpha} \\ \frac{l_m}{l_\alpha} & 0 & -\frac{l_s}{l_\alpha} & 0 \\ 0 & \frac{l_m}{l_\alpha} & 0 & -\frac{l_s}{l_\alpha} \end{bmatrix} \begin{bmatrix} \Psi_{ds} \\ \Psi_{qs} \\ \Psi_{dr} \\ \Psi_{qr} \end{bmatrix} \quad (2.16)$$

$$l_\alpha = l_m^2 - l_r l_m \quad (2.17)$$

Donde, l_s y l_r es la inductancia del estator y la inductancia del rotor respectivamente. Al remplazar las ecuaciones (2.10) y (2.11) en las ecuaciones (2.9), se obtienen los siguientes resultados:

$$v_{ds} = \left[\frac{d}{dt} + \frac{R_s}{l_s} \right] \Psi_{ds} - \omega \Psi_{qs} - \frac{R_s l_m}{l_s} i_{dr} \quad (2.18a)$$

$$v_{qs} = \omega \Psi_{ds} + \left[\frac{d}{dt} + \frac{R_s}{l_s} \right] \Psi_{qs} - \frac{R_s l_m}{l_s} i_{qr} \quad (2.18b)$$

$$V_{dr} = \frac{l_m}{l_s} \frac{d}{dt} \Psi_{ds} - (\omega - \omega_r) \frac{l_m}{l_s} \Psi_{qs} + \left(R_r - \frac{l_\alpha}{l_s} \frac{d}{dt} \right) i_{dr} + (\omega - \omega_r) \frac{l_\alpha}{l_s} i_{qr} \quad (2.18c)$$

$$V_{qr} = (\omega - \omega_r) \frac{l_m}{l_s} \Psi_{ds} - \frac{l_m}{l_s} \frac{d}{dt} \Psi_{qs} - (\omega - \omega_r) \frac{l_\alpha}{l_s} i_{dr} + \left(R_r - \frac{l_\alpha}{l_s} \frac{d}{dt} \right) i_{qr} \quad (2.18d)$$

En el SCIG, las tensiones de rotor en el eje directo y en cuadratura son cero. [15]

Las ecuaciones para la potencia activa P y potencia reactiva Q del generador de inducción de jaula de ardilla son los siguientes:

$$P_s = v_{ds} i_{ds} + v_{qs} i_{qs} \quad (2.19a)$$

$$Q_s = v_{qs} i_{qs} - v_{ds} i_{ds} \quad (2.19b)$$

Las ecuaciones (2.12) y (2.13) se describe la parte eléctrica de un SCIG. Sin embargo, también la parte mecánica debe tenerse en cuenta para las simulaciones de sistemas de potencia dinámicas. La siguiente ecuación del torque eléctrico desarrollado por un SCIG, [16].

$$T_{elec} = \frac{3}{2} p (\Psi_{ds} i_{qs} - \Psi_{qs} i_{ds}) \quad (2.20)$$

Los cambios en la velocidad del generador que resultan de la diferencia en el par eléctrico y mecánico se pueden calcular usando la ecuación de movimiento del generador.

$$\frac{d\omega_r}{dt} = \frac{1}{2H} (T_{elec} - F\omega_r - T_{mec}) \quad (2.21a)$$

$$\frac{d\theta_r}{dt} = \omega_r \quad (2.21b)$$

Donde H es la constante de inercia del rotor [s] y T_{mec} es el torque mecánico [p.u.], F es el coeficiente de amortiguamiento,[16].

CAPÍTULO 3

CONTROL PI EN LA TURBINA

3.1. Controlador PI del sistema eólico

Para el sistema de control propuesto se puede utilizar un controlador con acción de control proporcional-integral (PI), lo que permite que el sistema de control puede eliminar errores paramétricos o rechazar perturbaciones inesperadas y de esta manera comparar la salida con una referencia a seguir, lográndose que el controlador varíe las entradas adecuadamente. La acción de control de un controlador del tipo PI se define mediante la expresión:

$$u(t) = k_p e(t) + \frac{k_p}{T_i} \int_0^t e(t) dt, \quad (3.1)$$

donde:

$u(t)$: señal de salida del controlador.

K_p : ganancia proporcional.

T_i : constante del tiempo del integrador.

Este esquema de control puede ser representado de la siguiente manera:




Figura 3.1. Diagrama de bloques del controlador proporcional integral

Los términos K_p y T_i son ajustables. El cambio del valor de K_p afecta la parte proporcional de la acción del control, mientras que la constante del tiempo del integrador sólo ajusta la acción de control integral, [17].

Es necesario nombrar el sistema back-to-back, que consta de dos convertidores uno conectado al lado del rotor y el otro conectado a la red.




Figura 3.2. Esquema del convertidor Back-to-Back

El convertidor del lado del rotor se encarga de fijar las tensiones en el rotor y la potencia reactiva de la máquina mientras que el del lado de red se encarga de obtener o suministrar a la red potencia activa según el punto de funcionamiento de la máquina.

Un controlador **PI**, es usado para reducir el error de voltaje V_{DC} , la salida de este controlador es la referencia de la corriente I_{dref} ; la cual hace parte del control del convertidor del lado de la red, ver figura 3.4.

Lado de la red: En el caso del convertidor del lado de red su función es la de mantener constante la tensión V_{DC} en uno pu, sin importar la dirección del flujo de potencia del rotor y garantizar que el convertidor del lado red trabaja con el factor de potencia de referencia fijado. Este procedimiento se realiza mediante un lazo de control véase figura 3.3, [14].

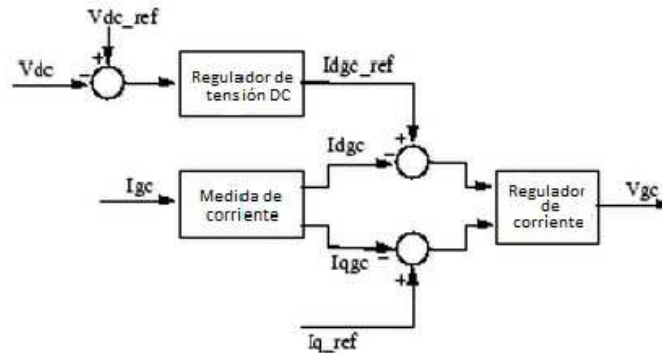


Figura 3.3. Sistema de control al lado del red

- Los sistemas que miden las componentes dq de las corrientes AC de secuencia positiva son controlados por la tensión DC (V_{DC}).
- La salida del regulador de tensión DC es la corriente de referencia (I_{dgc_ref}) para el regulador de corriente (I_{dgc} es la fase de corriente con tensión de la red que controla el flujo de potencia activa).

- El regulador de corriente controla la magnitud y fase de la tensión generada (V_{gc}) por el convertidor Ired desde la corriente I_{dgref} producida por el regulador de tensión DC y especifica la referencia I_{qref} .

Vdc regulator




Figura 3.4. Regulador de V_{DC} con control PI

CAPÍTULO 4

CONTROL ÓPTIMO USANDO REDES NEURONALES

4.1. Control óptimo

Uno de los problemas a enfrentar es el control de un sistema dinámico. Controlar un sistema requiere manipular sus entradas de manera que se comporte de acuerdo a las necesidades que el ambiente le imponga y a los cambios internos que el sistema experimente, en cada instante un controlador busca minimizar la diferencia entre el comportamiento deseado para el sistema y el comportamiento presentado por el mismo. En este sentido, el problema del control puede ser analizado como un problema de optimizar un criterio de desempeño o función objetivo que describe el comportamiento global de un sistema, [18].

El problema antes expuesto ha sido resuelto para muchas aplicaciones usando esencialmente criterios de estabilidad. A partir de este concepto se derivan propuestas como la realimentación de variables de estado y controladores PID aplicados en sistemas físicos lineales dado que en ellos es posible realizar un análisis en el dominio de la frecuencia. Estos controladores generalmente requieren que los modelos matemáticos sean linealizados y funcionan solamente en puntos de operación particulares. A pesar que es posible controlar en varios puntos de operación, la anterior dificultad obliga la necesidad de controles no-lineales.

La teoría de control óptimo ofrece solución a las dificultades descritas anteriormente. En este proyecto se implementó una metodología de control óptimo basada en el algoritmo de Levenberg - Marquardt (LM) el cual es utilizado por la red neuronal para su entrenamiento, el rendimiento del método de LM es determinado por el algoritmo de error mínimo cuadrado(MSE).

4.1.1. Algoritmo de optimización de Levenberg - Marquardt

Este algoritmo es la modificación del método de Newton. El método de newton para optimizar el rendimiento $e(x)$ es: [19].

$$X_{\{k+1\}} = X_k - A_k^{-1}g_k \quad (4.1)$$

$$A_k = \nabla^2 e(x) \Big|_{x=x_k} \quad (4.2a)$$

$$g_k = \nabla e(x) \Big|_{x=x_k} \quad (4.2b)$$

Si asumimos que $e(x)$ es una suma de funciones cuadráticas:

$$e(x) = \sum_{i=1}^n v_i^2(x) = v^T(x)v(x) \quad (4.3)$$

El gradiente puede ser escrito entonces en forma matricial:

$$\nabla e(x) = 2J^T(x)v(x) \quad (4.4)$$

Donde $\mathbf{J}(\mathbf{x})$ es la matriz jacobiana.

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

$$X_{k+1} = X_k - [J^T(x_k)J(x_k) + \mu_k I]^{-1} J^T(x_k)v(x_k) \quad (4.5)$$

O determinando directamente el incremento:

$$\Delta x_k = - [J^T(x_k)J(x_k) + \mu_k I]^{-1} J^T(x_k)v(x_k) \quad (4.6)$$

La nueva constante μ determina la tendencia el algoritmo, cuando μ_k se incrementa, este algoritmo se aproxima al algoritmo de pasos descendientes para tasas de aprendizaje muy pequeñas; cuando μ_k se decrementa este algoritmo se convierte en el método de Gauss–Newton,[19].

El algoritmo comienza con un valor pequeño para μ_k , por lo general 0.01, si en ese paso no se alcanza el valor para $e(x)$ entonces el paso es repetido con μ_k multiplicado por un factor $\vartheta > 1$. Si se ha escogido un valor pequeño de paso en la dirección de paso descendiente, $e(x)$ debería decrecer. Si un paso produce un pequeño valor para $e(x)$, entonces el algoritmo tiende al método de Gauss–Newton, el que se supone garantiza una rápida convergencia. Este algoritmo genera un compromiso entre la velocidad del método de Gauss–Newton y la garantía de convergencia del método de paso descendiente, [19].

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

$$[J]_{h,l} = \frac{\partial e_{k,q}}{\partial x_l}, \quad (4.7)$$

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

$$x^T = [x_1, x_2, \dots, x_n] = [w_{1,1}^1, w_{1,2}^1, \dots, w_{S^1,R}^1, b_1^1, \dots, b_{S^1}^1] \quad (4.8)$$

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

$$s_{i,k}^m = \frac{\partial e_{k,q}}{\partial n_{i,q}^m}, \quad (4.9)$$

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

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

$$[J]_{h,i} = \frac{\partial e_{k,q}}{\partial w_{i,j}^m} = \left(\frac{\partial e_{k,q}}{\partial n_{i,q}^m} \right) \left(\frac{\partial n_{i,q}}{\partial w_{i,j}^m} \right) = s_{i,h}^m \left(\frac{\partial n_{i,q}}{\partial w_{i,j}^m} \right) = (s_{i,h}^m) (a_{j,q}^{m-1}) \quad (4.10)$$

o para las ganancias:

$$[J]_{h,i} = \frac{\partial e_{k,q}}{\partial b_i^m} = \left(\frac{\partial e_{k,q}}{\partial n_{i,q}^m} \right) \left(\frac{\partial n_{i,q}}{\partial b_i^m} \right) = s_{i,h}^m \left(\frac{\partial n_{i,q}}{\partial b_i^m} \right) = (s_{i,h}^m) \quad (4.11)$$

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

$$S_q^M = -f^M(n_q^M) \quad (4.12)$$

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

$$S_q^M = f^M(n_q^M) (W^{m+1})^T S_q^{m+1} \quad (4.13)$$

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

$$S^m = [S_1^m] [S_2^m] \dots [S_Q^m] \quad (4.14)$$

Para cada nueva entrada que es presentada a la red, los vectores de sensibilidad son propagados hacia atrás, esto se debe a que se ha calculado cada error en forma individual, en lugar de derivar la suma al cuadrado de los errores. Para cada entrada aplicada a la red habrá S^M errores, uno por cada elemento de salida de la red y por cada error se generara una fila de la matriz Jacobiana, [19].

4.2. Redes neuronales artificiales

Las redes neuronales artificiales (RNA) simulan las propiedades observadas en los sistemas neuronales biológicos a través de modelos matemáticos recreados mediante mecanismos artificiales. Generalmente consisten en unas unidades llamadas neuronas, conectadas entre sí. Cada neurona toma un valor de entrada, el cual transforma según una función denominada función de activación. En la cual esta señal transformada pasa a ser la salida de la neurona.




Figura 4.1. Neurona biológica a la neurona artificial

Las neuronas se conectan entre sí, dependiendo de su arquitectura. Cada conexión tiene un determinado peso que examina cada entrada a la neurona. De esta manera la entrada de cada neurona es la suma de las salidas de las neuronas conectadas a ella, multiplicadas por el peso de la respectiva conexión. La siguiente figura 4.2 ilustra dicho concepto:

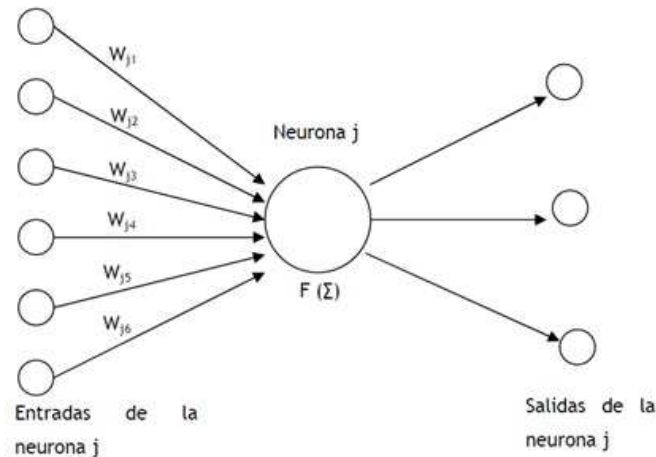


Figura 4.2. Esquema de funcionamiento de una neurona artificial

En este modelo, la neurona j recibe una serie de entradas X_1, X_2, \dots, X_n . Cada señal se multiplica por el peso asociado a su conexión, W_1, W_2, \dots, W_n . Luego, se suman

estas entradas ponderadas y se les aplica la función de activación $F(\cdot)$ para generar la señal de salida de la neurona j . Los valores de los pesos son ajustados durante la fase de aprendizaje, [20]. Este aprendizaje se hizo mediante el algoritmo de retropropagación.

Dependiendo de la estructura de la red neuronal, las neuronas se agrupan en distintas capas: una capa de entrada, otra de salida, y en el caso de existir, una o varias capas ocultas. En la figura 4.3 se muestra la estructura de la red con dichas capas

Las entradas a la red son introducidas en las neuronas de la capa de entrada, que regularmente genera una salida la cual se limita mediante la función de activación adecuada. Estas entradas son propagadas a las neuronas de la siguiente capa. De acuerdo al esquema de la figura 4.2 cada neurona j de la segunda capa generara una salida de valor:

$$S_{2j} = F_{2j}(X_1 W_{1j}) \quad (4.15)$$

Donde X_1 es el vector de entradas de la capa 1 y W_{1j} el vector de pesos correspondientes a las conexiones que van de todas las neuronas de la capa de entrada a la neurona j de la capa oculta o segunda capa. La función F_{2j} es la función de activación de la neurona j de la capa oculta. Así con todas las neuronas de esta capa. Estas salidas son propagadas a las neuronas de la capa de salida. Estas neuronas generan las salidas de la red. Cada neurona i de la capa de salida generara una salida de valor:

$$S_{sj} = F_{sj}(W_{2i} S_2) \quad (4.16)$$

Donde W_{2i} es el vector de pesos correspondientes a las conexiones que van de las neuronas de la capa oculta a la neurona i de la capa de salida, y S_2 el vector de salidas de las neuronas de la capa dos, que a su vez son entradas de las neuronas de la capa de salida.

Uno de los aspectos más importantes y delicado de redes neuronales, es el aprendizaje. Las RNA son sistemas de aprendizaje basadas en datos que son utilizados como patrones. Por ello la capacidad de una red de resolver un problema está muy ligada a los patrones utilizados durante su fase de aprendizaje.

El aprendizaje de una red neuronal consiste en hallar los valores precisos de los pesos de sus conexiones para que pueda resolver un determinado problema. El proceso general consiste en ir introduciendo una serie de datos patrón y ajustar los pesos siguiendo un determinado criterio. Los criterios que se van a utilizar en este proyecto se fundamentan en el error cometido por la red, lo que nos obliga a conocer la salida que se debería obtener para cada uno de ellos. Es lo que se conoce como entrenamiento supervisado. De esta manera, primero se introducen los patrones, se reajustan los pesos, posteriormente se comprueba si se ha cumplido un determinado criterio de convergencia, de no ser así se repite todo el proceso, [20].




Figura 4.3. Esquema de la arquitectura de una red

4.2.1. Tipos de Función de Activación

Combina las entradas con el estado actual de la neurona para producir un nuevo estado de activación. Esta función F produce un nuevo estado de activación en una neurona a partir del estado que existía y la combinación de las entradas con los pesos de las conexiones. Esa F es denominada función de activación, y las salidas se obtienen en una neurona para las diferentes formas de F , [21]. Las principales funciones de activación empleadas en las redes neuronales son:

a) Función Escalón (Hardlim)

La Figura 4.4, muestra como esta función de activación restringe la salida a valores entre 1 y -1, característica que le permite ser empleada en la red tipo Perceptrón.

$$a = \begin{cases} 1 & \text{si } n \geq 1 \\ -1 & \text{si } n < 1 \end{cases} \quad (4.17)$$

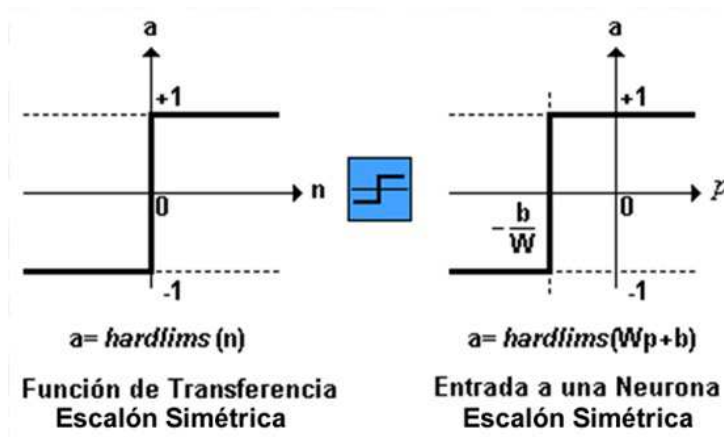


Figura 4.4. Función de Activación de Escalón simétrica

b) Función de Activación lineal (Purelin)

La salida de una función lineal es igual a su entrada, la cual se representa en la figura 4.5 Esta función de activación son utilizadas en la red tipo Adaline.

$$a = n \quad (4.18)$$




Figura 4.5. Función de Activación Lineal (Purelin)

c) Función de Activación sigmoïdal (logsig)

La función de la figura 4.6 toma los valores de entrada, los cuales pueden oscilar entre más y menos infinito, restringe la salida a valores entre cero y uno, de acuerdo a la expresión:

$$a = \frac{1}{1 + e^{-n}} \quad (4.19)$$

Esta función es comúnmente usada en redes multicapa, como la Backpropagation, en parte porque la función logsig es diferenciable.




Figura 4.6. Función de Activación Sigmoidal

Las principales funciones de Activación empleadas en las redes neuronales son:

Nombre	Relación Entrada /Salida	icono	Función en Matlab
Limitador Fuerte	$a = \begin{cases} 1 & \text{si } n \geq 0 \\ 0 & \text{si } n < 0 \end{cases}$		hardlim
Limitador Fuerte Simétrico	$a = \begin{cases} 1 & \text{si } n \geq 0 \\ -1 & \text{si } n < 0 \end{cases}$		hardlims
Lineal Positiva	$a = \begin{cases} 0 & \text{si } n < 0 \\ n & \text{si } 0 \leq n \end{cases}$		poslin
Lineal	$a = n$		purelin
Lineal Saturado	$a = \begin{cases} 0 & \text{si } n < 0 \\ n & \text{si } 0 \leq n \leq 1 \\ 1 & \text{si } n > 1 \end{cases}$		satlin
Lineal Saturado Simétrico	$a = \begin{cases} -1 & \text{si } n < -1 \\ n & \text{si } -1 \leq n \leq 1 \\ 1 & \text{si } n > 1 \end{cases}$		satlins
Sigmoidal Logarítmico	$a = \frac{1}{1 + e^{-n}}$		logsig
Tangente Sigmoidal Hiperbólica	$a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$		tansig
Competitiva	$a = 1$ Neurona con n max $a = 0$ El resto de las neuronas		compet

Figura 4.7. Funciones de Activación

4.2.2. Características de una Red Neuronal Artificial

Las RNA se caracterizan de acuerdo a cuatro aspectos principales: topología, el mecanismo de aprendizaje, tipo de asociación realizada entre la información de entrada y salida, y la forma de representación de esta información,[22].

Topología: Hace referencia a la organización y disposición de las neuronas en la red, formando agrupaciones llamadas capas. Los parámetros fundamentales son: el número de neuronas por capa, el grado de conectividad y el tipo de conexiones entre neuronas. Este último se utiliza para reconocer si las redes son de propagación hacia adelante

(feedforward); o hacia atrás (backpropagation); el número de capas permite saber si son mono capa o multicapa, [22] .

Mecanismo de Aprendizaje: El aprendizaje es el proceso por el cual una red neuronal modifica sus pesos en respuesta a una información de entrada. Durante este proceso los pesos de las conexiones de la red se modifican, cuando estos permanecen estables quiere decir que la red aprendió, [22].

Existen diferentes mecanismos de aprendizaje que le permiten a la red ir modificando sus pesos de acuerdo a una salida deseada; o interpretar de diferente manera las salidas que la red genere.

Tipo de asociación realizada entre la información de entrada y salida: Se refiere a los datos que la red aprende y asocia las entradas con las salidas correspondientes.

Forma de la representación de la información: los datos de entrada y salida de una red neuronal pueden ser representados de maneras distintas: análogas y discretas. Si son análogas le corresponde una función de activación continua por ejemplo la función lineal o sigmoideal; En el caso de entradas con valores discretos, la función de activación es de tipo escalón.

4.2.3. Principales tipos de redes neuronales

- **Perceptrón Simple:**

El modelo matemático más simple de una neurona es el perceptrón, la cual utiliza un aprendizaje supervisado. El perceptrón es una matriz para representar las RN y es una discriminador terciario que traza su entrada X (un vector binario) a un único vector de salida $f(x)$ (un solo valor binario) a travez de dicha matriz.

$$f(x) = \begin{cases} 1 & \text{si } n \geq 1 \\ 0 & \text{en otro caso} \end{cases} \quad (4.20)$$

Donde W es el vector de pesos reales y el $W \cdot X$ es producto punto (que computa una suma ponderada). U es el umbral, el cual representa el grado de inhibición de la neurona, es un término constante que no depende del valor que toma la entrada.

El valor de $f(x)$ (0 o 1) se usa para clasificar x como un caso positivo o negativo, en el caso de un problema de clasificación binario. El umbral puede pensarse de cómo compensar la función de activación o dando un nivel bajo de actividad a la neurona de rendimiento. La suma ponderada de las entradas debe producir un valor mayor que u para cambiar la neurona de estado 0 a 1, [22].

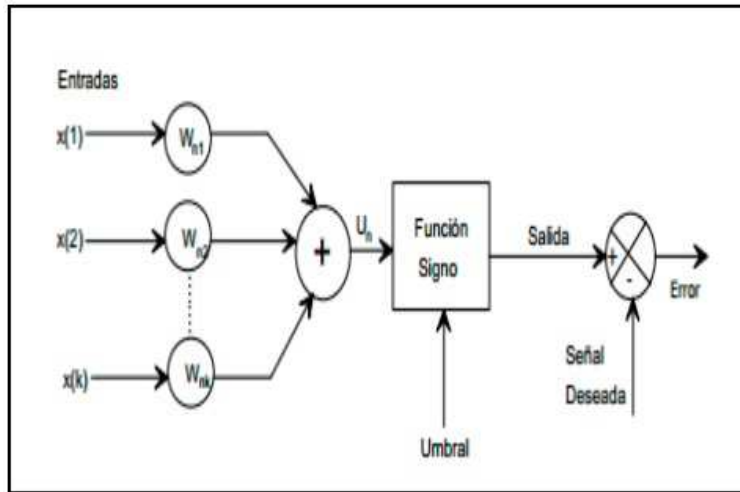


Figura 4.8. Perceptrón Simple

Regla del Perceptrón.

Es conocida como la primera regla para actualizar los pesos en una red neuronal, esta regla modifica los elementos W_k , de acuerdo al algoritmo básico de la regla del perceptrón, [22].

$$w_{k+1} = w_k + \alpha \frac{\epsilon_k}{2} X_k \quad (4.21)$$

Donde ϵ es calculado mediante la diferencia entre la salida deseada y la salida de la planta. Esta regla desarrollada por Rosenblatt, actualiza W_k , solo si el error ϵ_k^3 es diferente de 0. El vector de entrada es x_k , el nuevo vector de pesos W_{k+1} y α es la tasa de aprendizaje, que es un valor constante muy pequeño que no cambia en el tiempo, [23].

Como sabemos el perceptrón es un tipo de red supervisado, necesita conocer los valores esperados para cada una de las entradas presentadas a la red, por lo que se tiene pares de entrada - salida:

$$\{X_1, Y_1\}, \{X_2, Y_2\}, \dots, \{X_n, Y_n\} \quad (4.22)$$

Cuando las entradas X son representadas a la red, las salidas son comparadas con el valor esperado Y , y la salida de la red está dada por:

$$a = \sum_{i=1}^n W_i X_i \quad (4.23)$$

- **Perceptrón Milticapa:**

Es una red que utiliza un aprendizaje supervisado y en la que en mayor aplicación se ha utilizado; el Mutilayer Perceptron (MLP), está formado por una capa de entrada, al menos una capa oculta y una capa de salida, ver figura 4.9. Este tipo de redes una para su entrenamiento entrenamiento propagación hacia atrás (Backpropagation), conocida también como retropropagación del error o regla delta generalizada [24].

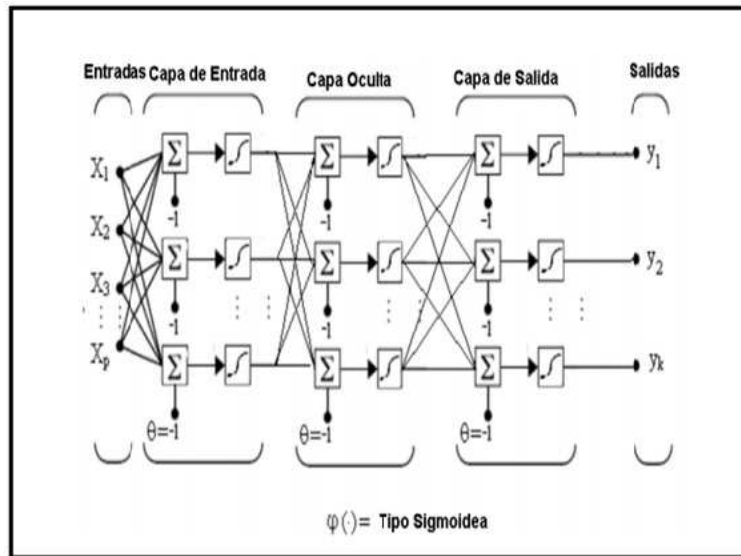


Figura 4.9. Perceptrón Multicapa

El conjunto de neuronas propagan la señal hacia la salida, las conexiones que conectan las neuronas son optimizadas por el algoritmo de aprendizaje. Se debe considerar el número de neuronas que forman las capas de la red; para la capa de entrada y salida se considera el problema a resolver; el número de capas ocultas y de neuronas en cada una de ellas son decididas por el diseñador.

Cada neurona realiza la propagación, haciendo una combinación de las señales que vienen de la capa anterior utilizando como coeficiente los pesos sinápticos.

Las funciones de activación no lineales más utilizadas son la Sigmoide y Tangente Hipérbolica, la cual toma valores entre 0 y 1, y entre -1 y 1 respectivamente.

Algoritmo de Entrenamiento Backpropagation (Regla Delta Generalizada)

Como se mencionó, el perceptrón multicapa utiliza un algoritmo de aprendizaje supervisado por corrección de error conocido como Backpropagation. Consiste en retropropagar la señal desde la capa de salida hasta la capa de entrada, optimizando los valores de los pesos a través de un proceso que se basa en la minimización de la función de coste la cual es el valor absoluto del error, el algoritmo se divide en dos fases: [24].

Propagación hacia adelante: Las señales se propagan desde la capa de entrada hacia la capa de salida, generando la salida y el error cometido por la red, al comparar la salida obtenida con la referencia.

Propagación hacia atrás: De acuerdo al error cometido obtenido al comparar la señal de salida y de referencia, el Backpropagation se encarga de corregir el valor de los pesos entre las conexiones de las neuronas mediante la retropropagación del error desde la capa de salida hasta la capa de entrada a través de las capas ocultas.

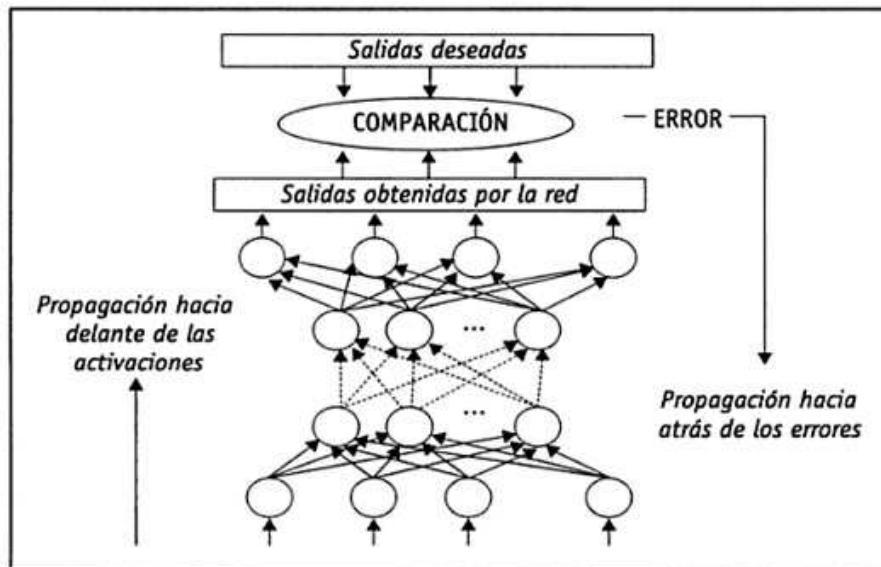


Figura 4.10. Esquema del modelo Backpropagation

Una neurona de la capa oculta se conecta con otra de la capa de salida como se muestra en la figura 4.11.

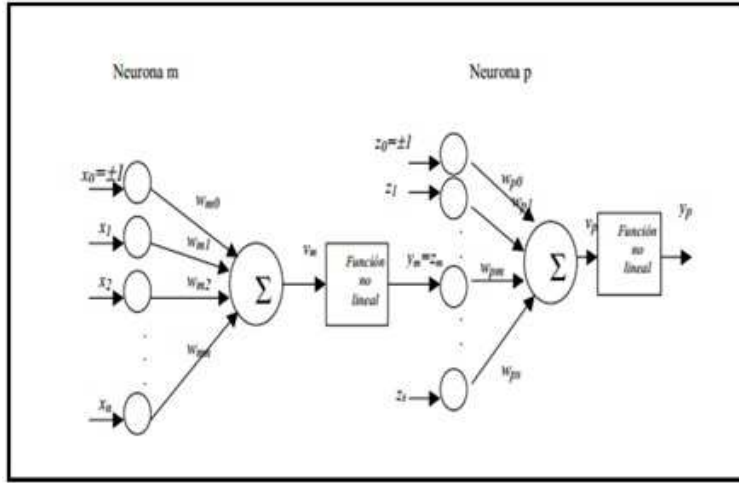


Figura 4.11. Una sola neurona oculta conectada con la neurona de la capa de salida

Donde X_1, \dots, X_n son las entradas de la capa oculta, x_o es la entrada que dependiendo si es 1 será el bias el cual cumple el objetivo de mejorar la convergencia de la red; por el contrario si es -1 será el umbral, el cual presenta la mínima entrada total ponderada necesaria para la activación de la neurona. Los valores W_{m1}, \dots, W_{mn} son los pesos que conectan las entradas con la neurona oculta m y W_{m0} es el peso sináptico correspondiente a X_o :

$$v_m = \sum_{i=0}^n W_{mi} * X_i(t) \quad (4.24)$$

El índice m indica la neurona y el índice indica el número de iteración, si a la función de activación se le denota por φ , la salida de la neurona es:

$$y_m(t) = \varphi_m(v_m(t)) \quad (4.25)$$

El conjunto y_m contiene las salidas de las neuronas de la capa oculta, es decir las entradas de la capa salida, los pesos que conectan estas entradas con la neurona p (de salida) serán h_{p1}, \dots, h_{pr} , p es la neurona y r el el número de neuronas ocultas, ahora e sesgo es h_{p0} :

$$z_p = \sum_{j=0}^r h_{pj} * y_j \quad (4.26)$$

si la función de activación (ϕ), la salida de la neurona de salida es:

$$o_m(t) = \varphi_p(z_p(t)) \quad (4.27)$$

Si el valor de la salida deseada se denota d_p , el error queda definido por:

$$e_p = d_p - o_p \quad (4.28)$$

Proceso de aprendizaje de un perceptrón multicapa.

En el proceso de aprendizaje:

- Se indican los pesos con valores aleatorios próximos a 0.
 - Se presenta un patrón n de entrenamiento $(X_{(n)}, S_{(n)})$, se propaga hacia la salida y se obtiene hacia la respuesta de la red $Y_{(n)}$.
 - Se evalúa el error que comete la red para cada neurona.
 - Se aplica Backpropagation para modificar los pesos de la red, empezando por la capa de salida hasta llegar hasta la capa de entrada.
 - Se repite el proceso hasta alcanzar el mínimo error.
- **Adaline:**

La red Adaline (Adaptative Lineal Neuron), es similar al perceptrón, excepto en su función de activación, la cual es una función de tipo lineal en lugar de un limitador fuerte en el caso del perceptrón, ver figura 4.12.

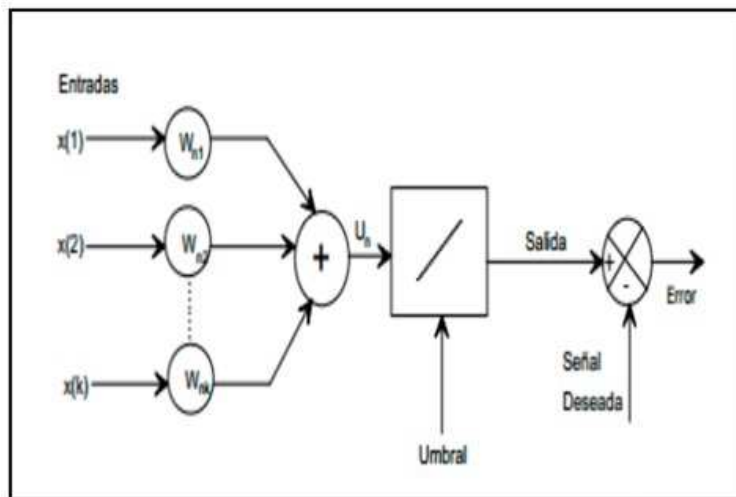


Figura 4.12. Red Adaline

El elemento de procesamiento realiza la suma de los productos de los vectores de entrada y de pesos, aplica una función de salida para obtener un único valor de salida, el cual debido a su función de activación lineal será $+1$ si la sumatoria es positiva o -1 si la salida de la sumatoria es negativa.

Algoritmo de Entrenamiento.

El entrenamiento del Adeline está basado en la regla LMS (Least Mean Square) que busca minimizar el error cuadrático medio por medio de la regla delta.

Dado un vector de entrada (x_0, \dots, x_n) donde $x_0 = 1$, el correspondiente valor de pesos (w_0, \dots, w_n) y el valor deseado de salida d , el error cuadrático es el siguiente:

$$E = \left[d(t) - \sum_{i=1}^n w_i(t) X_i(t) \right]^2 \quad (4.29)$$

El objetivo del método es minimizar dicho error mediante la modificación del vector de pesos (w_0, \dots, w_n) sumándole un Δw de tal forma que nos acerquemos al error mínimo en la dirección del gradiente negativo, es decir, lo más rápidamente posible.

El procedimiento de derivación se presenta a continuación:

$$E = d^2(x) - 2d(t) \sum_{i=1}^n W_i(t) X_i(t) + \left[\sum_{k=1}^n W_k(t) X_k(t) \right]^2 \quad (4.30)$$

$$\frac{\partial E}{\partial W_i} = -2 \left[d(t) - \sum_{k=1}^n W_k(t) X_k(t) \right] X_i(t) \quad (4.31)$$

Por lo que el error local será reducido más rápidamente si se ajustan los pesos de acuerdo a la regla delta:

$$\Delta W_1(t+1) = \eta \left[d(t) - \sum_{k=1}^n W_k(t) X_k(t) \right] X_i(t) \quad (4.32)$$

El algoritmo de entrenamiento se presenta a continuación:

1. Inicializar pesos (W_1, \dots, W_n) y threshold (W_0)
2. Presentar vector de entrada (X_1, \dots, X_n) y la salida deseada $d(t)$
3. Calcular la salida

$$y(t) = F_h \left[\sum_{i=0}^n W_i(t) * X_i(t) \right] \quad (4.33)$$

$$f_h(a) = \begin{cases} 1 & \text{si } a > 0 \\ -1 & \text{si } a \leq 0 \end{cases} \quad (4.34)$$

4. Adaptar los pesos.

$$W_i(t+1) = W_i(t) + \eta \left[d(t) - \sum_{k=0}^n W_k(t) * X_k(t) \right] X_i(t) \quad (4.35)$$

Donde $0 < i < n$ y η (n de eficiencia) es la tasa de aprendizaje

5. Repetir los pasos 2 a 4 hasta que las salidas reales y las deseadas sean iguales para todos los vectores del conjunto de entrenamiento.

Siguiendo este método se garantiza que, para un conjunto de entrenamiento adecuado, después de un número finito de iteraciones el error se reduce a niveles aceptables. El número de iteraciones necesarias y el nivel de error deseado depende de cada problema particular.

CAPÍTULO 5

SIMULACIÓN Y ANÁLISIS DE RESULTADOS

En este capítulo se muestra la simulación y resultados obtenidos a partir del modelo SCIG, el cual se implementó en MATLAB/SIMULINK. Las pruebas realizadas radican en implementar un control óptimo usando redes neuronales dinámicas para el control de potencia activa, por medio del regulador de voltaje V_{CD} . Lo anterior es realizado con el objetivo de comparar el rendimiento con el controlador convencional PI.

5.1. Modelo de la Red neuronal

Se utilizó el bloque Model Reference Controller del toolbox de Simulink, el cual reemplaza el bloque PI convencional, figura 5.1, para obtener el resultado de interés; Dicho bloque tiene como entradas la referencia y la salida de la planta y como salida la señal de control.

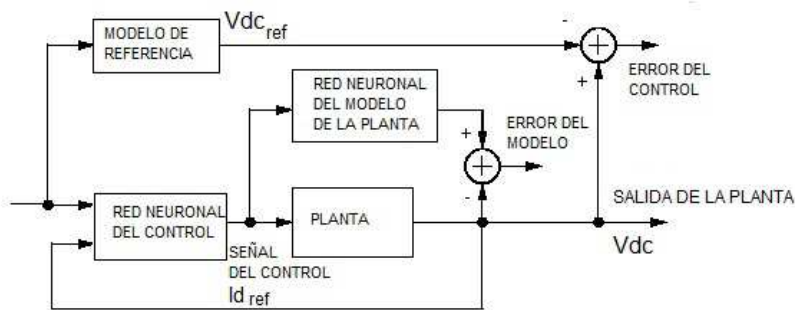


Figura 5.1. Regulador de V_{DC} con control de modelo de referencia

La arquitectura del controlador de modelo de referencia utiliza dos redes neuronales: una red de control y una red de modelo de planta. Se identifica primero el modelo de la planta, luego de esto el controlador debe ser entrenado para hacer que la salida de la planta siga el modelo de referencia.

A continuación se muestra con más detalle, en la figura 5.2, la estructura del Model Reference Controller. Cada red tiene dos capas, se puede seleccionar el número de neuronas para usar en las capas ocultas. Controlador tiene tres entradas las cuales son:

- Entradas retardadas de referencia.
- Salidas retardadas del controlador.
- Salidas retardadas de la planta.

Para cada una de estas entradas, se puede seleccionar el número de valores retardados. Generalmente el número de retardos es igual al orden de la planta. La planta tiene dos entradas:

- Salidas retardadas del controlador.
- Salidas retardadas de la planta.

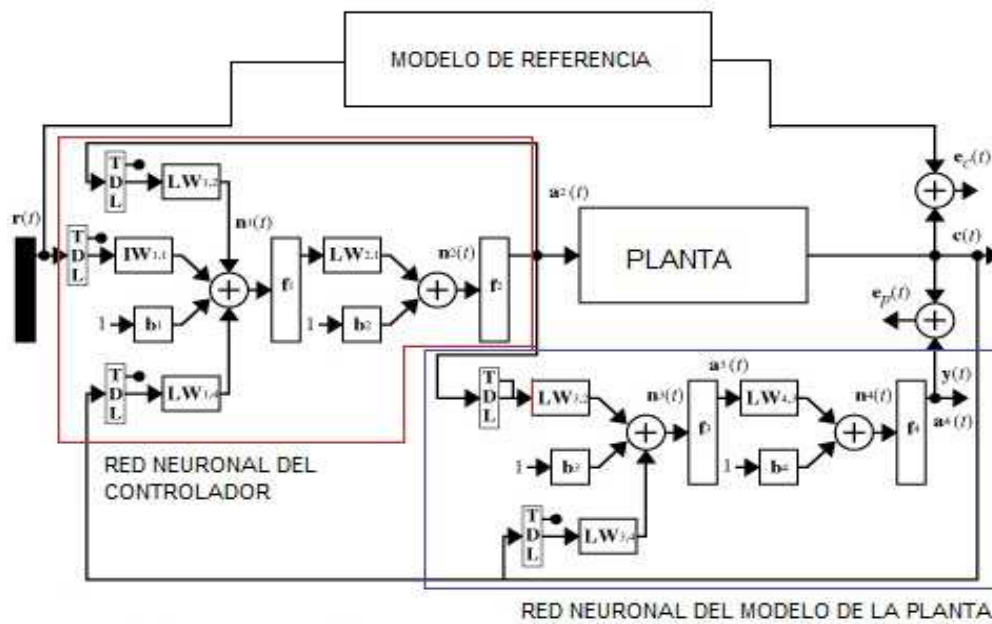


Figura 5.2. Arquitectura del controlador de modelo de referencia

5.2. Simulación

La estructura de red empleada, número de capas ocultas y número de neuronas por capa, se muestra en la figura 5.3.

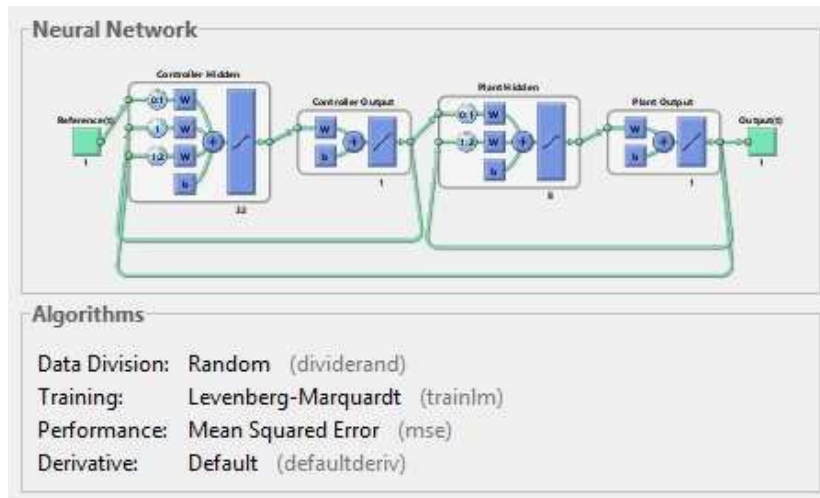


Figura 5.3. Estructura de la red neuronal

Para el sistema de control implementado fue necesario identificar la planta, esto se hizo tomando valores de entrada y salida, los cuales corresponden I_{dref} y V_{DC} respectivamente. En la siguiente figura se muestra dicha identificación realizada mediante el bloque Model Reference Control.

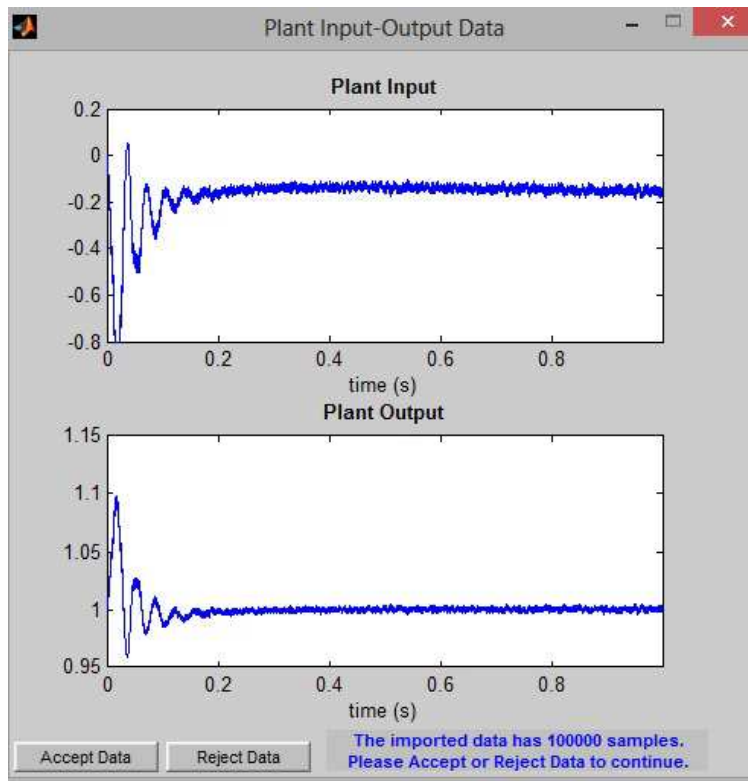


Figura 5.4. Entrada y salida de la planta

Ya identificada la planta, se entrenó la red con el método `trainlm`, ver sección 4.1.1, el cual consume mucha memoria pero muestra un buen desempeño de entrenamiento al converger rápidamente.

En la figura 5.5 se enseña el progreso del entrenamiento de la red, el número de iteraciones, la validación, la disminución del gradiente.

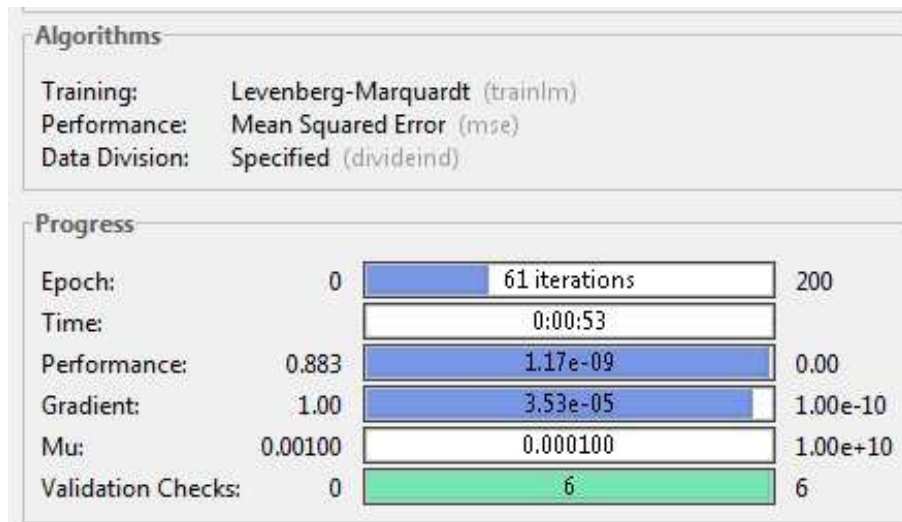


Figura 5.5. Progreso del entrenamiento de la red

La figura 5.6, muestra el desempeño de la red neuronal mientras avanza el entrenamiento, la línea azul denota el entrenamiento, la verde denota la validación, y la roja la evaluación. Para justificar un buen entrenamiento, el error medio cuadrático (MSE) debe ir disminuyendo y además que las tres líneas sigan el mismo patrón descendente, esto ayuda a un buen seguimiento de parámetros por parte la red. Para nuestro caso se nota que las tres líneas siguen el mismo patrón descendente mediante el MSE se reduce.

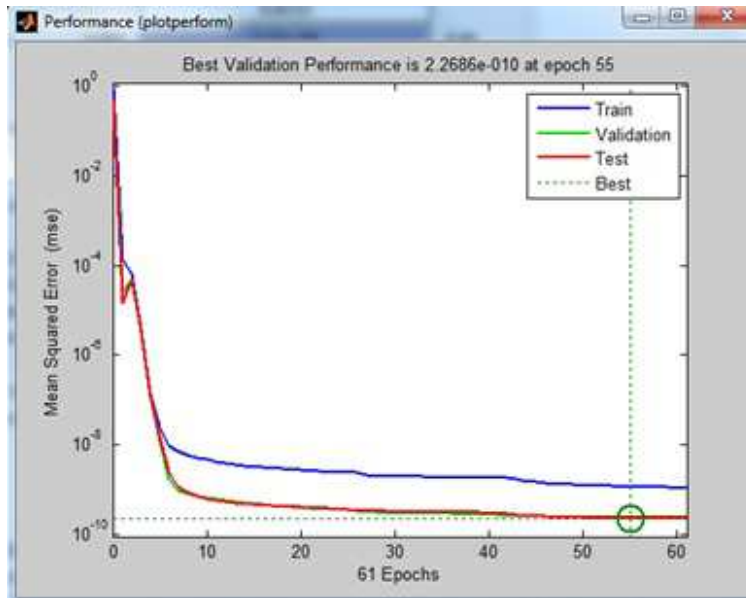


Figura 5.6. Rendimiento de la red

Una vez entrenada la red, se procede a entrenar el controlador, esto se hizo creando una función de transferencia con polos estables y estado estacionario igual a uno, la función de transferencia se creó en simulink, ver figura 5.7, tiene la particularidad de que al ser sometida a una entrada igual a uno, la cual corresponde a la referencia o V_{DCref} , esta llega a su referencia inmediatamente; Se tomaron datos de entrada y salida a dicha función de transferencia los cuales se usaron para entrenar el controlador de la red neuronal mediante el bloque model reference controller.

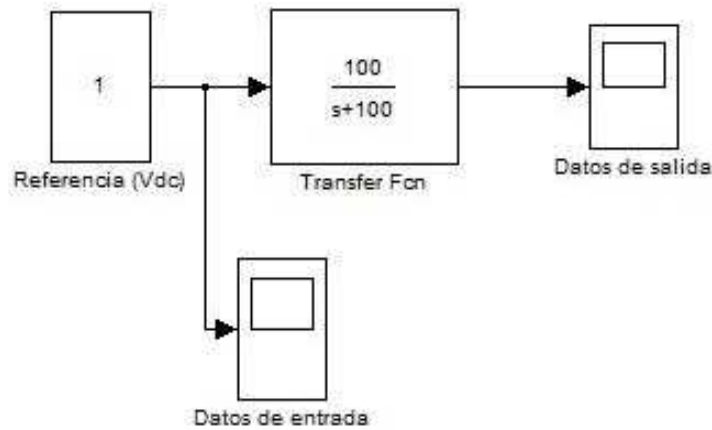


Figura 5.7. Función de trasferencia

Se Puede notar en la figura 5.8 que debido al previo entrenamiento del controlador, la salida del modelo llega a la referencia rapidamente, en gran parte esto se debe a la

función de transferencia que se usó para entrenar el controlador.

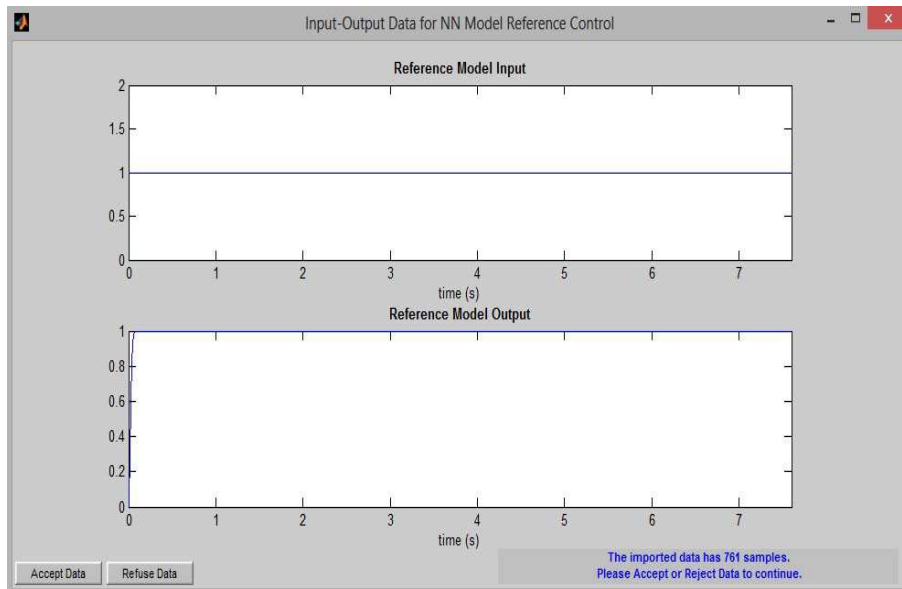


Figura 5.8. Entrada y salida del modelo de referencia

El resultado del entrenamiento de toda la de la red en general se muestra en la figura 5.9, en la cual se puede observar que salida de la red neuronal denotada de color verde sigue perfectamente en un tiempo muy corto la referencia (Vdc) de color azul.




Figura 5.9. Respuesta de la planta por las redes neuronales del control del modelo de referencia

5.3. Resultados.

A continuación se muestra los resultados del conjunto turbina-generador empleando un SCIG, con control PI y control con óptimo usando RND, aplicados al regulador de voltaje DC. Los resultados de interés se muestran en p.u., y corresponde al voltaje de enlace DC, potencia activa entregada a la red y corriente de eje directo, para una velocidad de viento variable entre 8 m/s y 18/s.




Figura 5.10. Señal de V_{DC} con controlador PI




Figura 5.11. Señal de V_{DC} con controlador óptimo usando RND




Figura 5.12. Señal de Potencia Activa con controlador PI

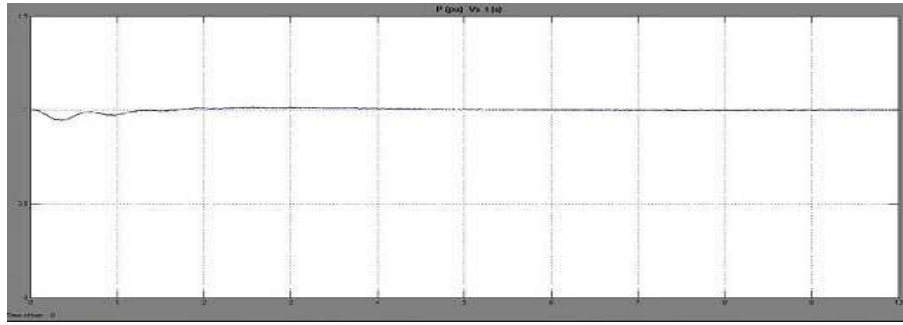


Figura 5.13. Señal de Potencia Activa con controlador óptimo usando RND




Figura 5.14. Señal de Corriente de eje directo con controlador PI




Figura 5.15. Señal de Corriente de eje directo con controlador óptimo usando RND

5.4. Análisis de resultados.

En esta parte del proyecto, se compara la acción de control en el enlace DC, potencia activa entregada a la red y corriente de eje directo, para una velocidad de viento

variable. Los resultados son obtenidos del sistema de generación eólica basado en SCIG empleando las técnicas de control mencionadas anteriormente.

Voltaje de enlace DC

Se puede notar en la figura 5.11 que con el controlador óptimo usando RND, el sistema responde rápidamente a la variación de viento, se presenta un sobreimpulso máximo aproximado a 1.2 p.u. alcanzando su referencia rápidamente a los 0.1s , se puede notar también que la señal de control se mantiene estable en el estado estacionario. En la figura 5.10 vemos que el controlador PI alcanza la referencia a los 0.2s y presenta un sobreimpulso significativamente alto de aproximadamente 1.4 p.u., en el estado estacionario la señal se mantiene estable.

Potencia activa entregada a la red

La figura 5.13 nos muestra la señal la de potencia activa generada por el controlador óptimo usando RND, se observa que se establece en 1 p.u. a los 1.5s aproximadamente, antes de esto, se presentan pequeñas oscilaciones por debajo de 1 p.u. debido a que la velocidad de viento es muy baja hasta ese tiempo. El controlador PI 5.12 logra establecer la señal de potencia a los 7 s aproximadamente, vemos que la señal en el estado transitorio presenta oscilaciones por debajo de 1 p.u. hasta los 2.3s y oscilaciones por encima de 1 p.u. hasta el establecimiento de la señal, lo anterior es debido a la fluctuación del viento que incrementa su valor desde 8 m/s hasta 18m/s.

Corriente de eje directo

En la figura 5.14 se puede notar que la señal de corriente de eje directo con controlador PI, se aproxima a valores cercanos a cero, teniendo en cuenta que esta es la señal de la diferencia entre el V_{DCref} y V_{DC} medido en el condensador, la cual se pretende llegar a valores muy cercanos a cero, esto se logra con el controlador óptimo usando redes neuronales dinámicas y se puede observar el resultado en la figura 5.15.

CAPÍTULO 6

CONCLUSIONES, RECOMENDACIONES Y TRABAJOS FUTUROS

6.1. Conclusiones.

Un controlador con redes neuronales dinámicas aplicado a un modelo de generador eólico funciona de forma óptima ante variaciones de viento, mostrando una rápida estabilidad en las variables controladas.

El control óptimo usando redes neuronales permite obtener un estado transitorio de control más reducido, mostrando una mayor eficiencia al aplicarlo a sistemas dinámicos, llevando los estados del sistema a los valores deseados.

La señal controlada con redes neuronales dinámicas presenta un sobreimpulso significativamente pequeño en comparación con el controlador PI, presentando una respuesta esperada debida al previo entrenamiento de la red.

Una buena identificación del sistema, además de los datos usados para el entrenamiento de la red neuronal influyen de manera trascendental para el control del sistema dinámico, con una buena experiencia la red neuronal tendrá la facultad de comportarse de una manera deseada ante las variaciones de viento.

Un número mayor de neuronas por capa de la red neuronal permite obtener un mejor seguimiento de la referencia en el entrenamiento de la red, pero este aumento de neuronas por capa hace que el entrenamiento consuma mucha memoria en el ordenador además de postergar el tiempo, hasta alcanzar el rendimiento óptimo esperado.

6.2. Recomendaciones.

Hay que tener en cuenta que la variación de viento desde su valor mínimo a máximo se haga dentro del tiempo en el cual se haga la toma de datos para el entrenamiento de la red, pues de esto depende en gran parte un buen desempeño de control.

Tener un ordenador con suficiente memoria y buen procesador es importante a la hora

de correr el programa en simulink ya que este es complejo y además el método de entrenamiento trainlm ocupa demasiada memoria cuando se hace el entrenamiento de la red

6.3. Trabajos futuros.

Analizar el comportamiento del sistema ante variaciones de carga además de variaciones de viento, proponiendo un control usando redes neuronales ante estas limitaciones que presentan las energías renovables.

Aplicar control óptimo usando redes neuronales para diferentes tipos de generadores así concluir cuál de estos presenta un mejor comportamiento ante este tipo de control y ante perturbaciones del sistema.

Proponer la inteligencia artificial como mecanismo de control para otros sistemas de obtención de energía eléctrica a partir de energías renovables.

BIBLIOGRAFÍA

- [1] J. M. Espí and J. Castelló, “Wind turbine generation system with optimized dc-link design and control,” *Industrial Electronics, IEEE Transactions on*, vol. 60, no. 3, pp. 919–929, 2013.
- [2] A. P. Sage and C. C. White, *Optimum systems control*. Prentice-Hall Englewood Cliffs, 1977, vol. 2.
- [3] M. Narayana and G. Putrus, “Optimal control of wind turbine using neural networks,” in *Universities Power Engineering Conference (UPEC), 2010 45th International*. IEEE, 2010, pp. 1–5.
- [4] R. Álvarez Munguía, “Mejora del rendimiento de un generador eólico asíncrono conectado a la red, mediante convertidores electrónicos y controladores de lógica difusa,” 2008.
- [5] W.-M. Lin and C.-M. Hong, “A new elman neural network-based control algorithm for adjustable-pitch variable-speed wind-energy conversion systems,” *Power Electronics, IEEE Transactions on*, vol. 26, no. 2, pp. 473–481, 2011.
- [6] ABB, *Cuaderno de aplicación técnicas Plantas eólicas*. ABB, 2012.
- [7] M. Stiebler, *Wind energy systems for electric power generation*. Springer Science & Business Media, 2008.
- [8] M. Yin, G. Li, M. Zhou, and C. Zhao, “Modeling of the wind turbine with a permanent magnet synchronous generator for integration,” in *Power Engineering Society General Meeting, 2007. IEEE*. IEEE, 2007, pp. 1–6.
- [9] D. L. Albarracín Avila, “Control de sistemas multivariables aplicado a un generador eólico conectado a un sistema de potencia,” 2013.
- [10] A. M. H. Sánchez, “Análisis, modelado y simulación de la operación de sistemas de generación eolieléctrica basados en generadores de inducción tipo jaula de ardilla,” 2008.
- [11] S. J. Chapman, *Máquinas eléctricas*. McGraw-Hill, 1991.
- [12] C. Carrillo, “Análisis y simulación de sistemas eólicos aislados,” *PhD, Universidade de Vigo (Spain)*, 2001.

- [13] P. Kundur, N. J. Balu, and M. G. Lauby, *Power system stability and control*. McGraw-hill New York, 1994, vol. 7.
- [14] M. Cañas Carretón, “Nuevas propuestas de resolución de modelos electromecánicos de aerogeneradores: aplicación a problemas de agregación,” 2013.
- [15] R. T. Derazkolaie, H. A. Shayanfar, and B. Mozafari, “Effects of rotor resistance value of scig on its output power and efficiency,” *Int. J. Pure Appl. Sci. Technol*, vol. 4, no. 1, pp. 41–48, 2011.
- [16] J. G. Slootweg, *Wind power: Modelling and impact on power system dynamics*. TU Delft, Delft University of Technology, 2003.
- [17] L. A. Barrios, “Modelado y control de pequeños sistemas de conversión de energía eólica basados en máquinas síncronas de imanes permanentes,” 2010.
- [18] D. A. Mejía, A. Molina, and J. C. Montero, “Diseño de un esquema de control óptimo neuronal,” *Scientia et Technica*, vol. 3, no. 32, 2006.
- [19] M. I. A. Buitrago and C. A. Z. Muñoz, “Tutorial sobre redes neuronales aplicadas en ingeniería eléctrica y su implementación en un sitio web,” *Universidad Tecnológica de Pereira*, 2000.
- [20] A. Moreno Rodríguez, “Desarrollo de una interfaz gráfica de redes neuronales usando matlab,” 2009.
- [21] M. Villanueva, “Las redes neuronales artificiales y su importancia como herramienta en la toma de decisiones,” *Trabajo de Investigacin-Universidad Nacional Mayor de San Marcos. Facultad de Ciencias Matemticas*, 2002.
- [22] E. C. A. Tepán, “Estudio de los principales tipos de las redes neuronales y las herramientas para su aplicación,” 2013.
- [23] C. A. O. Clavel, “Modelado y simulacion de un sistema de deteccion de intrusos utilizando redes neuronales recurrentes,” 2007.
- [24] X. B. Olabe, “Redes neuronales artificiales y sus aplicaciones,” *Publicaciones de la Escuela de Ingenieros*, 1998.