

ESTRATEGIA DE RE-ENTRENAMIENTO DE REDES NEURONALES PARA MEJORAR EL CONTROL DE LA EXCITACIÓN DE UNA MÁQUINA SÍNCRONA

RESUMEN

Las redes neuronales artificiales (RNA), ofrecen una alternativa para la implementación de controladores convencionales, debido a su capacidad de identificar y controlar sistemas no lineales, con una alta velocidad computacional. Esta técnica fue utilizada en la implementación de un controlador suplementario de la excitación (estabilizador de potencia), para mantener un buen comportamiento en la tensión en terminales de una máquina síncrona, cuando ésta es sometida a ciertas perturbaciones.

En este artículo se presentan los resultados obtenidos y se comprueba la efectividad del método aplicado, realizando la comparación con un estabilizador de potencia adaptivo y el controlador neuronal.

PALABRAS CLAVES: Control de tensión, redes neuronales, excitador, estabilizador de potencia, máquina síncrona

ABSTRACT

Artificial neural networks (ANN) offer an alternative to implementation of conventional controllers due the good performance to identify and control nonlinear systems at high computational speed. This technique was used in the supplementary controller implementation (power stabilizer) aimed to maintain an acceptable behavior of the terminal voltage in a synchronous machine, when it is under disturbance conditions.

In this paper the obtained results of the proposed approach are presented. The advantages of the use of neural nets over the classical adaptive implementation of power stabilizers are shown.

KEYWORDS: Voltage control, neural networks, exciter, power stabilizer, synchronous machine

SANDRA MILENA PÉREZ LONDOÑO*

Ingeniera Electricista, M.Sc
Profesor asistente
Universidad Tecnológica de Pereira
saperez@utp.edu.co

JUAN JOSÉ MORA FLÓREZ *

Ingeniero Electricista, Ph.D.(c)
Profesor auxiliar
Universidad Tecnológica de Pereira
jjmora@ohm.utp.edu.co

GERMÁN MORALES

ESPAÑA**

Ingeniero Electricista, M.Sc (c)
Universidad Industrial de Santander
gmorales@uis.edu.co

***Grupo de Investigación en Calidad de Energía Eléctrica y Estabilidad ICE³**

Grupo de Planeamiento de Sistemas Eléctricos – GPE

**** Grupo de Investigación en Sistemas Eléctricos - GISEL**

1. INTRODUCCIÓN

Las redes neuronales han sido exitosamente utilizadas en aplicaciones a los sistemas de potencia, como en análisis de contingencias, diagnóstico de fallas, modelado e identificación de los parámetros de las máquinas y despacho económico de sistemas de potencia, entre otros. [1, 2, 3, 4, 5]

Existen también referencias de la aplicación satisfactoria de las redes neuronales en la identificación y control de sistemas dinámicos [6,7], específicamente en el área del control adaptivo. En esta área, se encuentran múltiples desarrollos de estabilizadores de potencia para la máquina síncrona, con reportes de excelentes resultados [8,9,10].

El estabilizador de potencia (PSS, por su nombre en inglés Power System Stabilizer), que se presenta en la figura 1, es un controlador auxiliar de la máquina síncrona que, usado en conjunto con su sistema de excitación, provee señales de control que mejoran el amortiguamiento de las oscilaciones. El estabilizador controla el valor de la excitación aplicada al campo con

la ayuda del regulador automático de tensión (AVR, por su nombre en inglés Automatic Voltage Regulator), a través de la detección en el cambio de una variable de salida (potencia, velocidad, frecuencia), que se produce al ocurrir una perturbación en la máquina [11, 12].

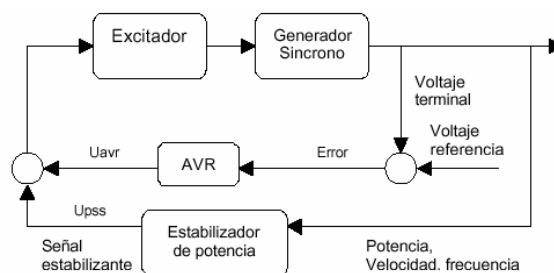


Figura 1. Control de la excitación en una máquina síncrona mediante operación conjunta de AVR y estabilizador

En la implementación de estabilizadores de potencia, han sido específicamente utilizadas dos tipos de redes: Las redes neuronales multicapa, utilizadas en problemas de reconocimiento de patrones y las redes recurrentes utilizadas en problemas de optimización.

Las principales referencias bibliográficas que se encuentran sobre la utilización de las redes neuronales en el diseño de estabilizadores de potencia, se ha centrado en las siguientes configuraciones:

- Una red neuronal:** En este caso la red neuronal es utilizada para sintonizar los parámetros de un estabilizador convencional (por ejemplo las ganancias proporcional, derivativa e integral), en tiempo real [13].
- Más de una red neuronal:** Aquí la red es utilizada para reemplazar al estabilizador. En esta aplicación la red es utilizada como controlador, lo cual obliga necesariamente a requerir de un controlador adicional que suministre un conjunto de datos de entrenamiento. Existen estudios, en los cuales no se utiliza este controlador adicional; sino que se utilizan dos redes neuronales, una trabaja como identificador y la otra como controlador [14] [15].

En este artículo se presenta la implementación de un estabilizador de potencia, basado en redes neuronales, de tipo supervisado, que utiliza inicialmente un conjunto de datos de pre-entrenamiento obtenido de otro estabilizador diseñado con una técnica adaptiva. Posteriormente con el fin de obtener mejores resultados, se considera una red neuronal adicional, que será encargada de generar un nuevo conjunto de datos para el controlador.

En la sección II se presenta una breve descripción de las redes perceptrón multicapa, utilizadas en este trabajo. En la sección III se presenta la estructura del controlador implementado en un montaje real en el laboratorio. En la sección IV se discute la estrategia de entrenamiento de las redes neuronales. Los resultados obtenidos se presentan en la sección V. Finalmente se presentan las conclusiones derivadas de esta implementación real.

2. MODELADO DE REDES NEURONALES

2.1 Redes perceptrón multicapa

Las redes “feedforward” (alimentadas hacia adelante) multicapa, son redes con una o varias capas ocultas que tienen una configuración tal como la que se presenta en la figura 2.




Figura 2. Estructura del perceptrón multicapa

Entre los elementos esenciales que operan en la estructura de la red, están: las entradas p_i , las conexiones sinápticas ponderadas w_i (matriz de pesos), el bias b_i , un sumador, la función de transferencia y la correspondiente salida t_i .

Cada neurona toma la suma de sus entradas más el *bias* y pasa el resultado a través de una función de activación para producir la salida. Entre las funciones de activación más utilizadas se encuentran la *sigmoide* y la *tangente hiperbólica*.

Estas redes han demostrado alta eficiencia en muchos problemas de clasificación de patrones, en diversas estrategias de aprendizaje como aprendizaje supervisado y no supervisado. Para el primer caso, las redes necesitan conocer los valores esperados para cada una de las entradas presentadas, de tal forma que es necesario conseguir un conjunto de datos de entrenamiento de la forma (1).

$$\{p_1, t_1\}, \{p_2, t_1\}, \dots, \{p_n, t_n\} \quad (1)$$

Para cada valor p en la entrada, corresponde un valor t en la salida.

Cuando p es aplicado a la red, la salida de la red s es comparada con el valor esperado t , y la salida de la red esta determinada por (2).

$$s = f\left(\sum_i w_i p_i\right) \quad (2)$$

Los valores de los pesos w_i , determinan el funcionamiento de la red. Estos valores se pueden fijar utilizando diferentes algoritmos de entrenamiento de la red, tales como propagación del error hacia atrás (backpropagation BP).

2.2 Algoritmo de entrenamiento BP

El entrenamiento de una red multicapa es considerado un problema de optimización, en el cual se busca minimizar una función de costo. El BP estándar es un algoritmo que ajusta los pesos w_i y “*bias*” de la red, en la dirección en la cual la función de costo decrece más rápidamente (el negativo del gradiente)

Una iteración de este algoritmo puede describirse según (3).

$$x_{i+1} = x_i - \alpha_i g_i \quad (3)$$

x_i es un vector de pesos y “*bias*” actuales, g_i es el gradiente actual, y α_i es la velocidad de aprendizaje.

Este algoritmo es utilizado en redes de aprendizaje supervisado, que emplea un ciclo propagación – adaptación hacia delante y hacia atrás. Una vez que se ha aplicado un patrón p a la entrada de la red, éste se propaga desde la primera capa hasta la capa de salida de la red. La señal de salida se compara con la salida deseada y se calcula una señal de error para cada una de las salidas. Una vez calculadas, las salidas de error se propagan hacia atrás, partiendo de la capa de salida (según la figura 3), hacia las neuronas de la capa oculta. Este proceso se repite, capa por capa, hasta que todas las neuronas de la red hayan recibido una señal de error que describa su contribución relativa al error total. Con esta señal de error se actualizan los pesos de conexión de cada

neurona, para hacer que la red converja hacia un estado que permita clasificar correctamente todos los patrones de entrenamiento.




Figura 3. Estructura del entrenamiento BP

3. ESTRUCTURA PROPUESTA PARA EL CONTROLADOR

La estructura inicial propuesta para el controlador utiliza dos subredes tipo perceptron multicapa, tal como se presenta en la figura 4. La primera subred es el controlador neuronal que se encargara de reemplazar al estabilizador adaptivo de la figura 1, mientras que la segunda subred denominada como “red correctora”, se encarga de mejorar el comportamiento del controlador en la etapa del entrenamiento.

3.1 Controlador neuronal

Es la red neuronal utilizada para reemplazar al estabilizador de potencia. Su estructura es un red multicapa, conformada por tres capas (entrada – oculta – salida). La red contiene tres entradas, una capa oculta de 15 neuronas y una neurona en la capa de salida, como se indica en la figura 4.




Figura 4. Configuración de las red utilizadas como controlador y red correctora.

La utilización de dos capas en la estructura propuesta, es justificada debido que esta configuración ha sido probada y definida como la más adecuada en aplicaciones de control [16]. Adicionalmente, el tiempo de procesamiento

es proporcional a la complejidad de la estructura de la red neuronal, y esta estructura se propone por ser la más sencilla y con mejores resultados.

Las variables que se utilizaron para definir el punto de operación de la máquina, son la potencia activa y el voltaje terminal. Estas variables fueron normalizadas de acuerdo al rango de operación en el que se considera la máquina, para generar el conjunto de datos de entrenamiento, dado en la tabla 1.

Patrón de entrada (pi)	Salida (t)
$Pa(k), Pa(k-1), Pa(k-2)$	$Upss(k)$

Tabla 1. Conjunto de entrenamiento para el controlador

$Pa(k), Pa(k-1)$ y $Pa(k-2)$, corresponden a los valores de la potencia activa en los instantes actual, y los dos anteriores. La salida de la red es la señal de salida del controlador $Upss(k)$. Estos datos son obtenidos de la implementación del estabilizador con una metodología adaptiva, cuando la máquina es sometida a diferentes perturbaciones [16].

3.2 Red correctora

Esta red es la red utilizada para ajustar el controlador neuronal. La estructura de esta red se define con dos entradas, 5 neuronas en la capa oculta y una neurona en la capa de salida, como se muestra en la figura 4.

El vector de datos de entrenamiento de esta red, esta dado por el conjunto de entrenamiento normalizado, dado en la tabla 2.

Patrón de entrada (pi)	Salida (t)
$Pa(k), Vt(k)$	$U(k)$

Tabla 2. Conjunto de entrenamiento para la red correctora

$Pa(k)$ es el valor de la potencia activa actual, $Vt(k)$ el voltaje en terminales de la máquina y $U(k)$ la señal de control que llega al sistema de excitación. Los datos también fueron recolectados con la máquina trabajando a diferentes condiciones de operación con perturbaciones.

4. ESTRATEGIA DE ENTRENAMIENTO DE LAS REDES NEURONALES

El proceso de entrenamiento del controlador está compuesto por dos etapas. La primera, se conoce como el *pre-entrenamiento*, en la cual se entrenan a las redes con los datos obtenidos con el estabilizador adaptivo. La segunda etapa es el *post-entrenamiento*, donde se re-entrena al controlador con los datos obtenidos con la ayuda de la red correctora. Ambas etapas se describen a continuación.

4.1 Recolección de datos mediante un estabilizador adoptivo

En [16] se presentó la implementación de un estabilizador de potencia basado en técnicas adaptivas.

Éste, mediante un identificador en línea del sistema, desarrolla la ley de control ajustable a diversas condiciones de operación de la máquina. El estabilizador se utiliza específicamente en este trabajo, para obtener un conjunto de datos de entrenamiento para las dos redes neuronales.

El proceso de recolección de datos se realizó cuando la máquina es sometida a cambios bruscos en la carga y en el voltaje terminal de referencia.

4.2 Entrenamiento de las redes neuronales (Etapa de pre-entrenamiento)

El entrenamiento fue desarrollado fuera de línea sobre ambas redes, con los datos obtenidos anteriormente con el algoritmo propagación hacia atrás (backpropagation).

Los pesos iniciales se establecieron en valores aleatorios entre -0.5 y 0.5.

En las técnicas de gradiente descendente, se utiliza un parámetro conocido como tasa de aprendizaje α , que varía entre 0 y 1. En esta aplicación en particular, se escogió con un valor de pequeño de 0.1, con el fin de evitar pasar por encima del punto mínimo de la superficie de error. Aunque este valor influye en la velocidad de convergencia del algoritmo, para este caso fue suficiente.

La implementación de las redes neuronales fue desarrollada usando el programa LabVIEW®, debido a la simplicidad en la creación del programa, facilidad de depuración de las rutinas implementadas y manejo de las librerías para adquisición de datos, que se utilizaron para desarrollar la implementación en el laboratorio. En la figura 11 (al final del documento), se presenta una ventana de diagramación de parte del código realizado en el entrenamiento de una red neuronal utilizando el algoritmo de entrenamiento descrito anteriormente.

4.3 Ajuste del entrenamiento (Etapa de post-entrenamiento)

Una vez se han entrenado ambas redes, se utiliza el controlador para reemplazar al estabilizador implementado con técnicas adaptivas, y a la red correctora se le cambia la entrada $V_t(k)$ por el voltaje terminal de referencia $V_{ref}(k)$, con el fin de determinar la señal $V_{op}(k)$. Esta última es la señal de entrada requerida para forzar al voltaje terminal sea igual al voltaje de referencia.

En la figura 5, se presenta la utilización en línea de las dos redes, con el fin de obtener un nuevo conjunto de datos de entrenamiento dado por la tabla 3, con el fin de re-entrenar al controlador.

Patrón de entrada (pi)	Salida (t)
$Pa(k), Pa(k-1), Pa(k-2)$	$V_{op}(k)$

Tabla 3. Nuevo conjunto de entrenamiento para el controlador

Una vez se han recopilado los datos, se utiliza la señal $V_{op}(k)$, para obtener el valor de la salida del controlador deseada en todo momento, según la ecuación (4).

$$Upss_{deseado} = V_{op} - U + Upss \quad (4)$$

U es la señal de control de entrada a la planta y $Upss$ es la salida que entrega el controlador.

Se realiza el cálculo de esta nueva variable y se ejecuta un nuevo entrenamiento fuera de línea, para el controlador con los datos $Pa(k), Pa(k-1), Pa(k-2)$ como señales de entrada y $Upss_{deseado}$ como salida. Una vez converge, se utiliza únicamente el controlador en línea con el sistema. Aquí termina el aporte de la red correctora.

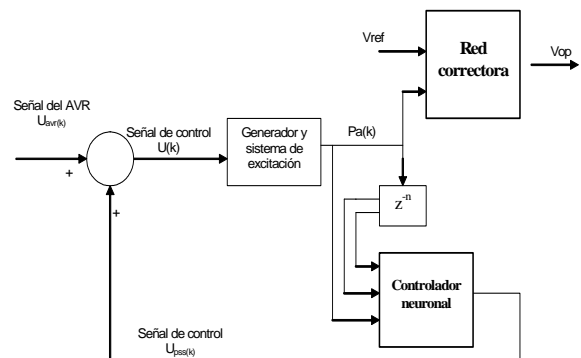


Figura 5. Recolección de datos usando el controlador neuronal y la red correctora

5. PRUEBAS Y RESULTADOS

5.1 Descripción del sistema de pruebas

El sistema utilizado en el laboratorio, se presenta en la figura 6, y consta de un primomotor con velocidad constante el cual acciona un generador sincrónico de 120VA, 220V, 60 Hz, 0.33A. La alimentación del circuito de campo se realiza a través de un excitador de estado sólido, que es controlado por el regulador automático de tensión (AVR), el cual fue implementado con una técnica clásica PI.

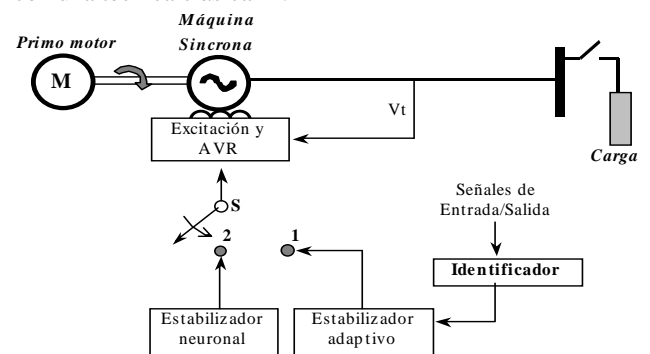


Figura 6. Configuración del sistema

En la figura 6, el conmutador S es utilizado para cambiar la configuración entre el estabilizador adaptivo y el neuronal. Cuando está en la posición 1, el sistema opera con el estabilizador adaptivo, y en esta posición es

utilizado cuando se desean obtener el conjunto de datos de entrenamiento para las redes. Cuando está en la posición 2, el sistema opera con el estabilizador neuronal ya re-entrenado previamente por la red correctora.

5.2 Perturbaciones realizadas sobre la máquina

El sistema descrito se sometió a diferentes tipos de prueba. En este artículo se presentan, las respuestas del sistema ante variaciones en el valor de la tensión de referencia. Se comparan los resultados obtenidos con el estabilizador adaptivo y el neuronal

5.2.1 Variación en la referencia de tensión de la máquina síncrona, para una carga con factor de potencia unitario

Con la máquina trabajando a una potencia de 0.8 pu y con un factor de potencia unitario, se realiza un incremento del 5% del voltaje de referencia a los cinco segundos. Este incremento se mantiene durante diez segundos, al cabo de los cuales se retorna al voltaje de referencia nominal. A los 25 segundos se incrementa la referencia en un 10% durante 15 segundos al cabo de los cuales se retorna a la referencia original.

La respuesta en voltaje entregada por el estabilizador adaptivo y el estabilizador neuronal ante esta perturbación, se presenta en las figuras 7 y 8, respectivamente.

Al observar la respuesta del estabilizador adaptivo, para la segunda perturbación de la figura 7, se tiene un tiempo de establecimiento de la señal de 7 segundos.

Al analizar el resultado entregado por el estabilizador neuronal se observa un tiempo de establecimiento para la misma circunstancia de segundo y medio, con una notable disminución en la oscilación con respecto a la implementación adaptiva.




Figura 7. Variación de ± 5 y $\pm 10\%$ en el voltaje de referencia, con estabilizador adaptivo, carga 0.8 pu, fp 1.




Figura 8. Variación de ± 5 y $\pm 10\%$ en el voltaje de referencia, con estabilizador neuronal, carga 0.8 pu, fp 1.

5.2.2 Variación en la referencia de tensión de la máquina síncrona, para una carga con factor de potencia en atraso

Con la máquina trabajando a una potencia de 0.95 pu con un factor de potencia 0.96 en adelanto, se realiza un incremento a los cinco segundos del 10% de la referencia. Pasados cinco segundos se retorna al voltaje de referencia nominal. A los 15 segundos se decrementa la referencia en un 10% durante 5 segundos al cabo de los cuales se retorna a la referencia original.

La respuesta en voltaje entregada por el estabilizador adaptivo y el neuronal, se presenta en las figuras 9 y 10, respectivamente.

Con el estabilizador adaptivo el establecimiento de la señal se obtiene a los dos segundos, con una considerable oscilación. Al analizar el resultado entregado por el estabilizador neuronal se observa un tiempo de establecimiento un poco inferior, pero con una notable disminución en la oscilación con respecto al controlador adaptivo.

Posteriormente, cuando se produce el decremento del 10% en el voltaje de referencia a los 15 segundos, el estabilizador neuronal realiza la transición en una forma más suavizada, más amortiguada que la adaptiva.




Figura 9. Variación de $\pm 10\%$ en el voltaje de referencia, con estabilizador adaptivo, carga 0.95 pu, fp 0.96 en atraso.




Figura 10. Variación de $\pm 10\%$ en el voltaje de referencia, con estabilizador neuronal, carga 0.95 pu, fp 0.96 en atraso.

6. CONCLUSIONES

Mediante la aplicación de la estrategia de control de la excitación de la máquina síncrona que se propone en este trabajo, se obtuvieron resultados que mejoran la capacidad de atenuar las oscilaciones de la tensión en terminales, ante variaciones en el nivel de referencia y en la carga.

La comparación entre el controlador neuronal y el adaptivo, muestra un mejor desempeño el primero, ante las perturbaciones consideradas. La respuesta entregada por el estabilizador neuronal ante diferentes perturbaciones a la máquina, supera a la técnica adaptiva,

como una consecuencia de la estrategia de reentrenamiento implementada mediante utilización de la red neuronal correctora.

Es importante aclarar que la efectividad del control implementado, se demostró para las condiciones específicas de prueba a las que fue sometida la máquina. Para cualquier otra condición de perturbación (tales como saturación, variación de los parámetros, entre otros), no podría realizarse una generalización de la pertinencia de este tipo de control.

7. BIBLIOGRAFÍA

[1] Mora J, Pérez L, G. Carrillo. "Fault location in power distribution systems using ANFIS nets and current patterns" En memorias del IEEE PES Transmission and Distribution Conference and Exposition: Latin America. Caracas. 2006, ISBN 1-4244-0288-3.

[2] R. Mahanty; P. Gupta; "Application of RBF neural network to fault classification and location in transmission lines" IEE Proceedings Generation, Transmission and Distribution, Vol 151, Issue 2, March 2004, pp(s):201 – 212

[3] Rubaai, A., R. Kotaru "Online Identification and Control of a DC Motor using Learning adaptation of neural networks" IEEE Trans. On Industry applications, vol 36, no 3, May/June 2000, pp 935 – 942.

[4] Bompard, E.; Chicco, G.; Napoli, R.; Piglione, F. "Fast contingency analysis by means of a progressive learning neural network" International Conference on Electric Power Engineering, 1999. PowerTech Budapest 99.

[5] M. Calvo ,O. P. Malik, "Machine parameter estimation as a pattern recognition problem," in Proc. IEEE Power Eng. Soc. Summer Meeting, Vancouver, BC, Canada, Jul 15–19, 2001.

[6] K.S. Narendra y K. Parthasarathy, "Identification and control of dynamical systems using neural networks",

IEEE. Trans. Neural Networks, vol. 1, no. 1, pp. 4-27, Mar. 1990

[7] K.J. Hunt, D. Sbarbaro, R. Zbikowski, P.J. Gawthrop, "Neural networks for control systems – A survey", Automatica, vol.28, no6, pp. 1083-1112, 1992.

[8] Hsu, Y. Y., & Chen, C. L. (1991). Tuning of power system stabilizers using an artificial neural network. IEEE Transaction on Energy Conversion, 6(4), 612–619.

[9] Segal, R., Kothari, M. L., & Madhani, S. (2000). Radial basis function (RBF) network adaptive power system stabilizer. IEEE Transactions on Power Systems, 15(2), 722–727.

[10] Liu, W., G. Venayagamoorthy, D. Wunsch, "Adaptive neural network based power system stabilizer design", IEEE Trans. On EC, 2003, pp 2970 – 2975.

[11] Paucar & Rudnick. "El estabilizador de potencia en el amortiguamiento de las oscilaciones electromecánicas en sistemas eléctricos multimáquina", X Conimera, Lima, 1997

[12] P. M. Anderson and A.A. Fouad, Power systems control and stability, Iowa State Univ. Press, Ames, Iowa, U.S. A., 1977

[13] Shamsollahi, P., O.P. Malik, "Direct Neural Adaptive Control to synchronous generator", IEEE Trans. On energy conversion, vol 14, No. 4, 1999, pp 1341 – 1346.

[14] Shamsollahi, P., O. P. Malik, "Application of neural adaptive power system in a multi-machine power system", IEEE Trans. On energy conversion, vol 14, No. 3, 1999, pp 731 – 736.

[15] Shamsollahi, P., O. P. Malik, "Real-time implementation and experimental studies of a neural adaptive power system stabilizer", IEEE Trans. On energy conversion, vol 14, No. 3, 1999, pp 737 – 742.

[16] Pérez S, Mora J, G. Olguin. "Maintaining Voltage Profiles by Using an Adaptive PSS" En memorias del IEEE PES Transmission and Distribution Conference and Exposition: Latin America. Caracas. 2006, ISBN 1-4244-0288-3

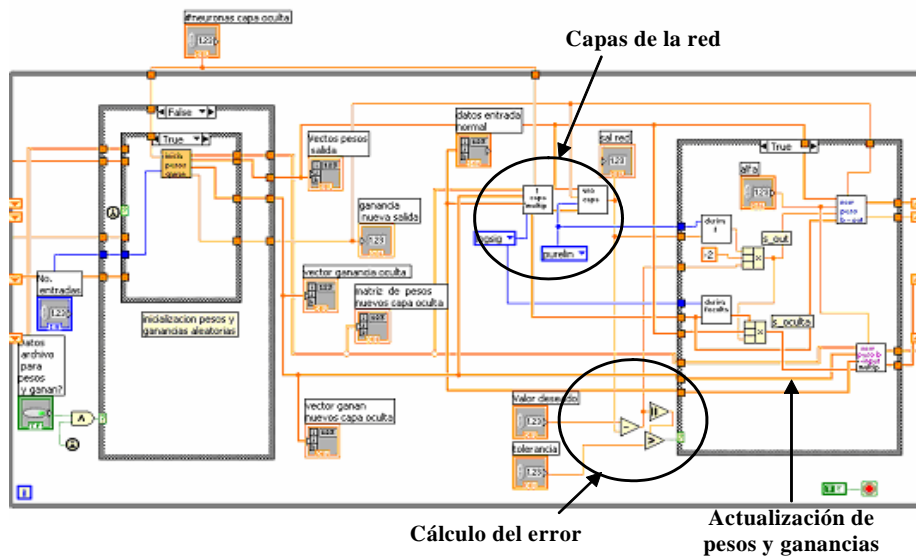


Figura 11. Ventana de diagramación del programa LabVIEW®, desarrollado para el entrenamiento de las redes