

APLICACION DE REDES NEURONALES ARTIFICIALES PARA LA SOLUCION DEL PROBLEMA DE FLUJO DE POTENCIA EN SISTEMAS DE ENERGIA ELECTRICA

Dr. Leonardo Paucar Ing. Marcos J. Rider
lpaucar@ieee.org mjrider@ieee.org

Facultad de Ingeniería Eléctrica y Electrónica, Universidad Nacional de Ingeniería
Departamento de Ingeniería Eléctrica, Universidade Federal do Maranhão

RESUMEN

Este artículo propone la utilización de redes neuronales artificiales (RNA) para resolver el problema del flujo de potencia en sistemas de energía eléctrica. El flujo de potencia calcula el estado en régimen permanente de un sistema eléctrico de potencia (SEP) y es una herramienta fundamental para el planeamiento, operación y control de los modernos SEP. El modelo matemático del flujo de potencia corresponde a un conjunto de ecuaciones algebraicas no lineales que pueden ser resueltas convencionalmente con el método iterativo Newton-Raphson (NR) o con sus versiones desacopladas. Actualmente se disponen de diversos programas computacionales comerciales que usan tales métodos. Entre los objetivos de la solución del problema flujo de potencia basado en RNA que aquí se propone, destaca su potencial aplicación para resolver problemas que exigen un gran esfuerzo computacional tales como el análisis de seguridad estática on-line y el análisis de contingencias. La metodología propuesta fue aplicada a los sistemas de prueba Ward-Hale de 6 barras e IEEE de 14 barras (IEEE-14), observándose resultados exitosos en términos de precisión aritmética y tiempo de procesamiento, en comparación con otros métodos convencionales.

ABSTRACT

This paper proposes the use of artificial neural networks (ANN) for solving the power flow problem in electrical energy systems. The power flow computes the steady state of an electric power system (EPS). Such a result becomes a fundamental tool for planning, operation and control of modern power systems. The mathematical model of the power flow can be described by a set of non-linear algebraic equations and solved using the iterative Newton-Raphson (NR) method (or its decoupled versions). At the present we can find commercial computer programs based on NR methods. Among the objectives of the proposed approach, we can highlight its potential application for solving problems in the presence of computational burden such as the on-line static security analysis and the contingency screening. The proposed methodology has been successfully applied to the following bus test systems: Ward-Hale 6 and IEEE-14. The simulation results show satisfactory arithmetic precision and processing time in comparison with other conventional methods.

INTRODUCCION

La operación de los modernos sistemas eléctricos de potencia (SEP), también denominados sistemas de energía eléctrica, se realiza desde centros de control y sistemas de manejo de la energía (EMS por *Energy Management System*) en los cuales se conducen avanzadas funciones computacionales, en modos *off-line* y *on-line*, tales como: control automático de la generación, estimación del estado, análisis topológico, análisis de la seguridad estática, etc. [1]

Todas las funciones de control en los EMS tienen el objetivo de mantener la tensión de cada barra y la frecuencia del sistema dentro de un intervalo de valores

adecuados con el fin de minimizar el impacto de las inevitables perturbaciones que ocurren en los SEP, mientras se satisfacen los requerimientos de la demanda y calidad de la energía. [1, 2]

Fundamental para la realización de todas aquellas funciones en los EMS es la solución del problema del flujo de potencia (FP), el cual consiste en determinar el estado de un sistema de potencia en régimen permanente expresado por las tensiones en barras, magnitudes y ángulos, y los flujos de potencia activa y reactiva en las líneas de transmisión de los SEP. Matemáticamente el problema FP consiste en

la solución de un sistema de ecuaciones algebraicas no lineales las cuales puede ser resueltas usando el método convencional Newton-Raphson (NR) y sus versiones desacopladas BX y XB. La consideración de conceptos de dispersidad en los programas basados en el método NR mejora aún más la velocidad y eficiencia para SEP a gran escala. [3, 4]

A pesar de la velocidad y eficiencia de los métodos NR, hay aplicaciones en sistemas de potencia para las cuales es necesario acelerar mucho más el proceso de solución del problema del flujo de potencia. Por ejemplo, para el análisis de seguridad estática se necesita resolver un gran número de casos de flujo de potencia en un corto período de tiempo de algunos minutos. Para sistemas eléctricos prácticos es muy difícil resolver a tiempo todos los casos PF requeridos, ya que la solución comprende la ocurrencia de muchas contingencias. [4, 5]

Las técnicas de inteligencia artificial (IA) están siendo aplicadas exitosamente en diversos problemas de la ingeniería. Así por ejemplo, aplicaciones de redes neuronales artificiales (RNA), conjuntos difusos (*fuzzy sets*), computación evolutiva, minería de datos, computación suave, y otras novedosas técnicas IA constituyen áreas de investigación muy activas en la ingeniería eléctrica, electrónica y de computación.

La ingeniería de potencia, un área tradicional de la ingeniería eléctrica, también muestra un número creciente de aplicaciones IA. Por ejemplo, la técnica de las redes neuronales está siendo usada para resolver problemas en planeamiento, análisis de seguridad, detección y diagnóstico de fallas, control, protección y diseño. El pronóstico de la demanda, análisis de seguridad y detección de fallas son los problemas más populares de las aplicaciones de RNA en sistemas de potencia. [6]

En el presente artículo se describe la aplicación de redes neuronales artificiales para la solución del problema de flujo de potencia y su potencial utilización en análisis de seguridad y análisis de contingencias. El perceptron multicamada (MLP por *multilayer perceptron*) sin realimentación es la arquitectura de red neuronal más utilizada en ingeniería [7] y sistemas de potencia y será adoptada en este trabajo. Se considera que este tipo de red neuronal es capaz de resolver problemas complejos con similar o superior dificultad que el problema no lineal del flujo de potencia. La presente metodología propuesta basada en RNA se aplica en dos sistemas de potencia estándares

de prueba con resultados satisfactorios.

METODOLOGIA PROPUESTA BASADA EN REDES NEURONALES

La mayoría de las aplicaciones de redes neuronales adoptan el paradigma del entrenamiento supervisado, siendo el perceptron multicamada sin realimentación la arquitectura preferida, mientras que el método de entrenamiento de retropropagación de errores (BP por *backpropagation error*) es utilizado en más del 80% de aplicaciones con RNA [7, 6]. En consecuencia, para el problema del flujo de potencia que nos ocupa adoptaremos tales consideraciones.

En la Fig.1 se muestra la metodología propuesta de redes neuronales para la solución del problema del flujo de potencia, donde x es el vector de datos de entrada; y^c , y^d son las salidas calculada y deseada respectivamente, y e es el error.

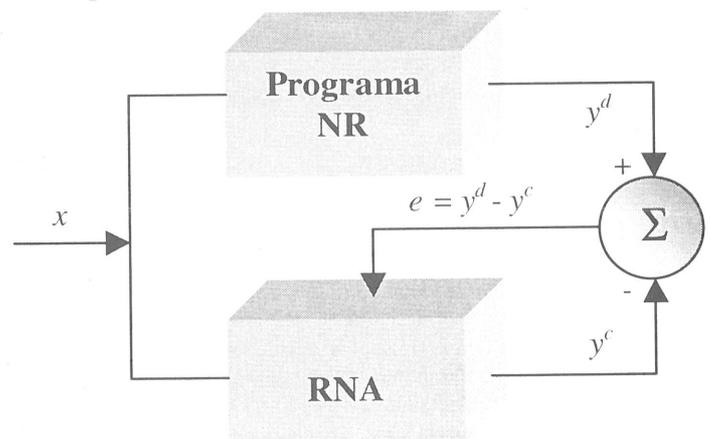


Fig. 1 Diagrama de bloques del método de aprendizaje supervisado aplicado al entrenamiento de redes neuronales a fin de realizar el cálculo del estado en régimen permanente de un sistema de potencia.

La arquitectura RNA propuesta se muestra en la Fig.2 y está compuesta de una única camada escondida de neuronas con funciones de activación tangente hiperbólica. El conjunto de datos de entrada considera la red eléctrica representada por los elementos normalizados de la diagonal de la matriz admitancia, la generación de potencia activa de cada generador, menos la barra de holgura (*slack*), las cargas modeladas como potencia constante y las magnitudes de tensión de las barras de generación. La salida está compuesta de todas las magnitudes de tensión de todas las barras PQ y los ángulos de las tensiones de todas

las barras PV y PQ. Debe recordarse que la mayoría de las barras de los sistemas de potencia son clasificadas típicamente en tipos PQ, PV y *slack*, las cuales corresponden a las barras de carga, barras de generación y barras de tensión constante o de holgura, respectivamente [2]. La función de activación para las unidades de salida es una función lineal.

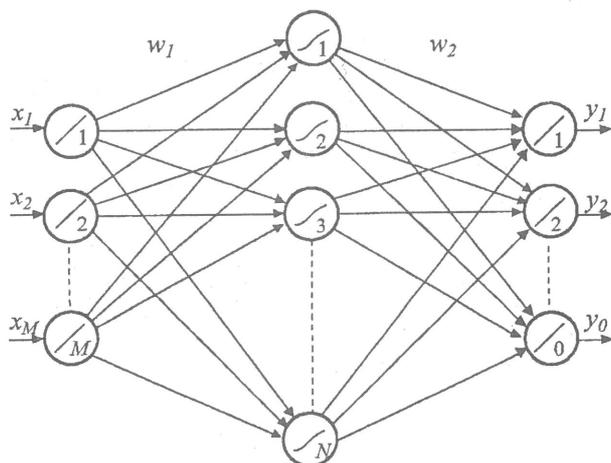


Fig. 2 Diagrama esquemático de la red de perceptrons multicamada propuesta para resolver el FP.

Para la generación de los datos de entrenamiento y de prueba se ha supuesto variación en el nivel de carga del sistema y la ocurrencia de un gran número de contingencias simples consistentes en salidas y refuerzos de líneas de transmisión, pérdida de generadores, variación de los taps de los transformadores y compensaciones shunt, y diferentes niveles de tensiones de generación. En la literatura se encontró que los datos de entrenamiento generalmente no cubren todos los casos mencionados, y en su mayoría están relacionados apenas con salidas de líneas de transmisión y diferentes niveles de carga del sistema. [8, 9]

Para un entrenamiento conveniente es necesario considerar diferentes contingencias y topologías, además de un número adecuado de escenarios de carga del sistema a fin de obtener una buena generalización de las redes neuronales. Dentro de las contingencias simuladas no fueron consideradas aquellas que causan no convergencia y las que producen subsistemas aislados. Esos últimos casos se resuelven separadamente de los subsistemas resultantes.

A pesar de la gran familiaridad de la ingeniería de potencia con el problema de flujo de potencia, existen pocas publicaciones relacionadas con su solución mediante redes neuronales [10, 8]. Este artículo explora

la idea de una red neuronal artificial como un resolvidor del flujo de potencia para un sistema de potencia dado.

El error de tensión en %, e_{ij} , dado por la ecuación (1), se define como el valor absoluto de la diferencia entre el valor calculado por la RNA entrenada y el valor calculado con un programa de flujo de potencia Newton-Raphson, multiplicado por 100. Un criterio de parada del entrenamiento de la red neuronal puede ser el error de tensión promedio e_{Vav} dado por la ecuación (3), la cual tiene que ser menor que un número pequeño ϵ .

$$e_{vij} = |V_{ij}^{NN} - V_{ij}^{NR}| * 100\% \quad (1)$$

$$e_{\theta ij} = |\theta_{ij}^{NN} - \theta_{ij}^{NR}| * 100\% \quad (2)$$

$$e_{Vav} = \frac{1}{n * nb} \sum_{j=1}^n \sum_{i=1}^{nb} e_{vij} \quad (3)$$

$$e_{\theta av} = \frac{1}{n * nb} \sum_{j=1}^n \sum_{i=1}^{nb} e_{\theta ij} \quad (4)$$

En las ecuaciones (1) al (4):

i, j = número de barra, número del caso de FP.

nb = número total de barras.

n = número de todos los casos de FP simulados.

V_{ij}^{NN}, V_{ij}^{NR} = magnitudes de las tensiones calculadas con RNA y NR, respectivamente.

$\theta_{ij}^{NN}, \theta_{ij}^{NR}$ = ángulos de las tensiones calculadas con RNA y NR, respectivamente.

$e_{vij}, e_{\theta ij}$ = errores de tensión y ángulo, simples

$e_{Vav}, e_{\theta av}$ = errores de tensión y ángulo, promedios

De todos los casos de flujos de potencia generados se seleccionó aleatoriamente un conjunto de datos para el entrenamiento de la red neuronal y el resto para la prueba de la red entrenada. Después del entrenamiento, la red neuronal debe ser capaz de calcular todas las magnitudes y ángulos de las tensiones de las barras del sistema para el cual la red fue entrenada y considerando cualquier otra condición de operación, tales como la ocurrencia de contingencias simples, nuevos ajustes de los taps de los transformadores y compensaciones shunt, etc. Tanto los casos de interpolación como de extrapolación fueron tomados en cuenta para ser exitosamente resueltos luego de realizado el entrenamiento de la red neuronal propuesta.

Para un entrenamiento mejorado de la red neuronal se utiliza un método de entrenamiento de segundo orden derivado de la familia de métodos back-propagation. Con los métodos de segundo orden pueden obtenerse resultados bastante precisos y con tiempos de procesamiento mucho menores que con el BP estándar, por ejemplo. No obstante, existe la dificultad de la dimensión del problema ya que se requiere más memoria cuando se usan métodos de segundo orden y ello puede comprometer en algunos casos una aplicación a gran escala como es el caso de los sistemas de potencia actuales que envuelven una gran cantidad de datos de entrada. [7, 11, 12].

RESULTADOS DE LA APLICACION A LOS SISTEMAS DE PRUEBA

Los sistemas de prueba Ward-Hale de 6 barras (WH6) y el IEEE-14 fueron usados para probar la metodología propuesta. Las redes neuronales fueron entrenadas hasta que el valor absoluto del gradiente de la función de error sea menor que $\varepsilon = 1e-6$.

Después del entrenamiento, la RNA está lista para calcular las magnitudes y ángulos de las tensiones de cualquier nueva contingencia y nivel de carga del sistema de potencia para el cual fué entrenada.

Como resultados exactos (*benchmark*) se han tomado los valores calculados con un programa FP Newton-Raphson para el cual se adoptó un error (*mismatch*) máximo de potencia $\delta = 5.0e-4$ pu como valor de parada de las iteraciones NR [2].

Una generalización mejorada del método en la aplicación de la RNA propuesta se consigue con un número adecuado de datos de entrenamiento y prueba. En el caso que nos ocupa, el generador de la barra *slack* no se tomó en cuenta en la lista de contingencias de salida de generadores. El nivel de variación de los taps de los transformadores fue de 0.9 a 1.1 pu y usando pasos pequeños. La conexión/desconexión de compensaciones shunt se simuló solamente para aquellas barras que tienen dicha opción, con pasos discretos comprendidos entre -6 a 0 y de -5 a 25 MVAR para los sistemas Ward-Hale y IEEE-14, respectivamente. Las tensiones de generación fueron variadas de 1.0 a 1.15 pu, incluyendo la barra *slack*.

Los refuerzos de redes se simulaban con la adición paralela de una nueva línea de transmisión o con un transformador de potencia.

A. Sistema de prueba Ward-Hale de 6 barras

El sistema Ward-Hale está compuesto de 6 barras, 7 ramas, 2 transformadores, 2 generadores, 2 compensaciones shunt variables y 3 cargas. En la Fig. 3 se representa su diagrama unifilar.

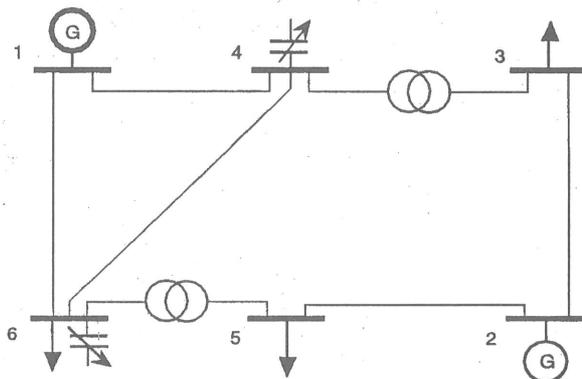


Fig. 3. Diagrama unifilar del sistema Ward-Hale.

En la Fig. 4 se ha graficado el perfil de tensiones para 338 casos aleatorios de flujos de potencia. Se espera que al final del entrenamiento la red neuronal haya aprendido perfiles similares a los casos mostrados y además haya adquirido una capacidad de generalización que le permita a la RNA poder calcular tensiones con niveles de carga y contingencias no presentadas durante la fase de entrenamiento; es decir, casos nuevos.

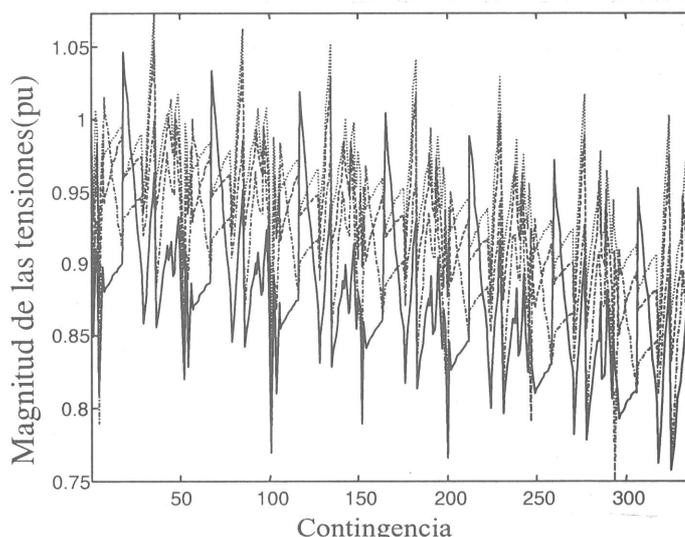


Fig. 4 Tensiones de las barras PQ del sistema Ward-Hale para 338 casos aleatorios de FP.

La arquitectura más adecuada de la red neuronal fue seleccionada usando validación cruzada [7].

La RNA propuesta está compuesta de 21 unidades de entrada, 16 neuronas en la camada escondida y 9 unidades de salida. El nivel de carga activa del caso base es 135 MW. Fueron considerados 14 escenarios de carga entre 105 y 165 MW. Cada nivel de carga tiene su propio caso base sin contingencia además de los respectivos casos con contingencias. Para todos los escenarios de carga y contingencias fueron generados 509 casos de flujos de potencia. La red neuronal fue entrenada con 7 condiciones de carga que incluyeron 254 casos FP. Luego del entrenamiento la red neuronal fue probada usando los 7 restantes escenarios de carga y los 255 casos FP.

En la Tabla 1 se detallan las magnitudes y ángulos de las tensiones para el peor caso de todos los datos de prueba usando la red neuronal y también usando un programa de flujo de potencia NR, puede notarse que los resultados son bastante parecidos. El peor caso correspondió a 117.5 MW de carga del sistema bajo la ocurrencia de la contingencia número 1 y ha sido verificado en la tensión de la barra N° 6. Se puede ver que el error máximo de la magnitud de tensión fue 0.53 % y el error de magnitud de tensión promedio para todos los casos probados fue 0.06 %. Coincidentemente, el error máximo del ángulo también ocurrió para el mismo nivel de carga y contingencia.

Tabla 1. Comparación de las salidas NR y RNA para el caso de prueba con máximo error V, sistema Ward-Hale

Barra N°	Flujo NR		Red Neuronal		Error (%)	
	V (pu)	θ (deg)	V (pu)	θ (deg)	e_{Vij}	$e_{\theta ij}$
1	1.0500	0.00	1.0500	0.00	0.00	0.00
2	1.1000	-26.14	1.1000	-26.88	0.00	1.30
3	0.8114	-24.00	0.8072	-24.41	0.42	0.72
4	0.8859	-19.37	0.8810	-19.65	0.49	0.50
5	0.8252	-33.09	0.8213	-33.75	0.39	1.15
6	0.8205	-33.33	0.8152	-33.98	0.53	1.12

En la Fig. 5 se grafican las magnitudes de tensión de la barra N° 6 para todas las contingencias y para un nivel de carga de 117.5 MW. En la misma Fig.5 se incluye el error máximo de la magnitud de la tensión para todos los casos de prueba.

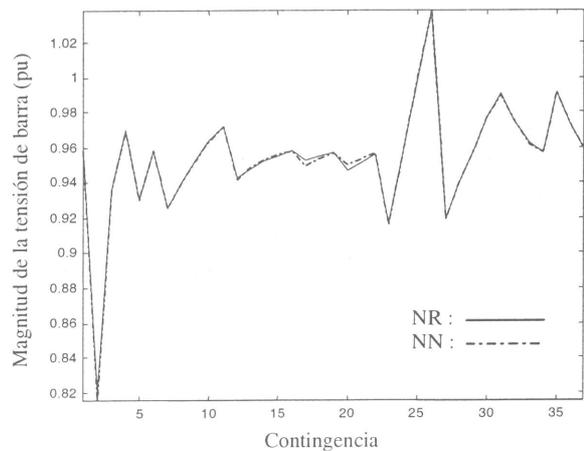


Fig. 5 Tensión en barra N°6 bajo contingencias simples cuando la carga del sistema Ward-Hale es 117.5 MW.

Adicionalmente, todos los 509 casos de flujo de potencia se resolvieron con un programa NR inicializado con *flat start* ($V=1.0$ pu, $\theta=0^\circ$) y fueron requeridas 1547 iteraciones NR, lo cual se traduce en un valor promedio de 3.04 iteraciones-NR/caso. Por otro lado, cuando el mismo número de casos fueron inicializados con los valores calculados por la red neuronal, se necesitaron 509 iteraciones-NR; es decir, 1.0 iteraciones-NR/caso, lo cual representa una ganancia (*speedup*) total de 67.1 % en tiempo de CPU para las iteraciones NR.

B. Sistema de prueba IEEE-14

El sistema IEEE-14 está compuesto de 14 barras y 20 ramas. Su diagrama unifilar se muestra en la Fig. 6. Este sistema se simuló con 11 escenarios de carga siendo 6 para entrenamiento y 5 para prueba. Los niveles mínimo y máximo de carga fueron 219 y 319 MW, respectivamente, mientras que el caso base tiene un nivel de carga de 259 MW.

El número total de casos de flujos de potencia generados fue 748, de los cuales 408 casos se escogieron aleatoriamente para entrenamiento y los restantes 340 casos se destinaron para prueba de la red neuronal. Esas cantidades corresponden a un gran número de casos, similar a aquellos encontrados en aplicaciones de análisis de seguridad de sistemas de potencia reales [12].

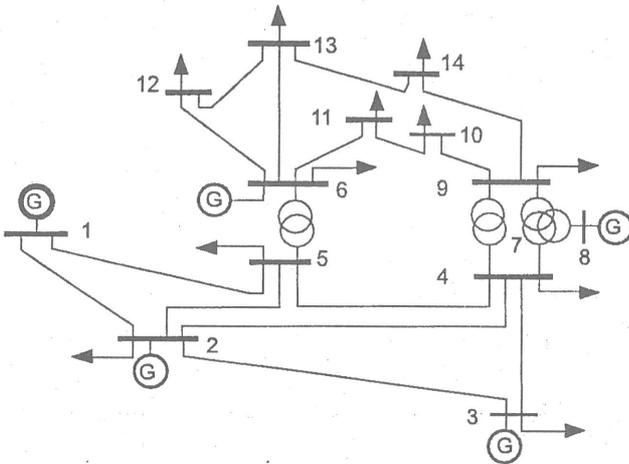


Fig. 6 Diagrama unifilar del sistema IEEE 14.

La arquitectura de la red neuronal propuesta está compuesta de 46 unidades de entrada, una única camada escondida con 26 neuronas y 22 unidades de salida. Para un entrenamiento típico de la red neuronal, los errores máximos de prueba en magnitud y ángulo de la tensión fueron 0.64% y 0.58%, respectivamente.

El error promedio de las magnitudes de tensión para todos los casos de prueba fue $e_{V_{av}} = 0.05\%$. El máximo error en las magnitudes de tensión para todos los casos de prueba fue identificado para la barra N°11 cuando la carga total fue 234 MW y el sistema experimentó la contingencia N° 8. Los resultados correspondientes a ese peor caso se muestran en la Tabla 2. Además se incluye una comparación entre las tensiones calculadas con un programa computacional Newton-Raphson y con la red neuronal propuesta. La similitud de los valores benchmark determinados con el flujo de potencia NR y los calculados con la red neuronal es una evidencia del buen comportamiento de la red neuronal entrenada exitosamente.

En la Fig. 7 se incluye el perfil de las magnitudes de tensión en la barra N° 11 vs. contingencias, y para el nivel de carga de 234 MW, nivel que originó el máximo error de tensión durante la etapa de prueba.

Por otra parte, los 748 casos FP fueron resueltos vía el flujo de potencia NR con *flat start* en 2027 iteraciones, en promedio 2.7 iteraciones-NR/caso. Cuando los mismos casos fueron resueltos con la red neuronal propuesta más el NR como refinador, entonces fueron requeridas 845 iteraciones-NR con un valor promedio de 1.13 iteraciones-NR/caso.

Tabla 2. Comparación de las salidas NR y RNA para el caso de prueba con máximo error V , sistema IEEE-14

Barra N°	Flujo NR		Red Neuronal		Error (%)	
	V (pu)	θ (deg)	V (pu)	θ (deg)	$e_{V_{ij}}$	$e_{\theta_{ij}}$
1	1.0600	0.00	1.0600	0.00	0.00	0.00
2	1.0450	-4.66	1.0450	-4.71	0.00	0.09
3	1.0100	-11.72	1.0100	-11.74	0.00	0.04
4	0.9993	-9.21	1.0004	-9.27	0.11	0.10
5	1.0019	-7.69	1.0029	-7.62	0.10	0.12
6	1.0000	-12.37	1.0000	-12.39	0.00	0.03
7	1.0045	-12.54	1.0040	-12.54	0.05	0.01
8	1.0000	-12.54	1.0000	-12.54	0.00	0.01
9	0.9996	-14.33	0.9975	-14.43	0.21	0.18
10	0.9901	-14.75	0.9871	-14.85	0.30	0.16
11	0.9843	-15.03	0.9779	-14.88	0.64	0.26
12	0.9868	-13.33	0.9881	-13.27	0.13	0.10
13	0.9827	-13.51	0.9841	-13.44	0.14	0.12
14	0.9749	-15.00	0.9748	-14.85	0.01	0.26

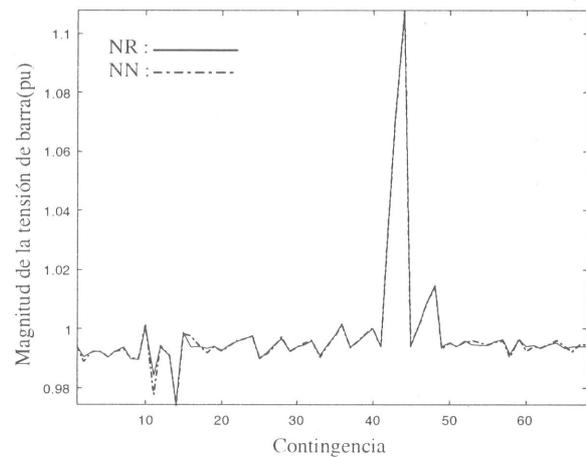


Fig. 7 Tensión en barra N°11 bajo contingencias simple cuando la carga del sistema IEEE-14 es 234 MW.

C. Desempeño de las redes neuronales propuestas

Un análisis de los resultados en las Tablas 3 a 5 indica que las RNA dan resultados muy aproximados para todos los casos de entrenamiento y prueba. En el supuesto de requerirse una mayor precisión pueden refinarse los resultados de las RNA usando por ejemplo un flujo de potencia NR, en cuyo caso se requerirán menos iteraciones, lo cual es valioso en situaciones de análisis de contingencias.

En todas las simulaciones, los resultados de RNA+NR dieron resultados mejores o similares que el NR con partida plana. Las redes neuronales también fueron probadas con contingencias dobles y los resultados obtenidos fueron aceptables si bien en algunos casos sea requerido un mayor refinamiento.

Las tasas del número de iteraciones-NR/caso fueron las mismas cuando las RNA fueron probadas con casos adicionales de prueba, 663 para el WH6 y 2406 para el IEEE-14, sin necesidad de recurrir a una etapa de re-entrenamiento de las redes neuronales.

Tabla 3. Comparación de las iteraciones con NR y con (RNA+NR) para los casos de entrenamiento y prueba

Sistema	Casos	Iteraciones		Iteraciones/caso	
		NR	RNA+NR	NR	RNA+NR
WH6	509	1547	509	3.04	1.00
IEEE-14	748	2027	883	2.71	1.18

Tabla 4. Resultados del entrenamiento de las RNA.

	Ward-Hale		IEEE-14	
	V	θ	V	θ
Número de casos	254		408	
e_{\max} (%)	0.52	1.14	0.88	0.78
e_{av} (%)	0.06	0.10	0.06	0.08
Epocas	7.7 e4		1.0 e5	

Tabla 5. Resultados de las pruebas de las RNA

	Ward-Hale		IEEE-14	
	V	θ	V	θ
Número de casos	255		340	
e_{\max} (%)	0.53	1.30	0.64	0.58
e_{av} (%)	0.06	0.09	0.05	0.08

No obstante los buenos resultados obtenidos, puede percibirse que la aplicación de la metodología propuesta a sistemas de potencia de gran escala aún no parece factible debido a la gran dimensión de las variables de entrada y a la necesidad de una red neuronal con muchas neuronas. Actualmente los autores investigan metodologías alternativas para aplicaciones de redes neuronales en sistemas de

potencia de gran dimensión, pues los resultados obtenidos reportados en este trabajo permiten concluir que hay una gran posibilidad de resolver el problema del flujo de potencia con redes neuronales simples entrenadas con métodos de entrenamiento mejorados, tanto en precisión como en velocidad de procesamiento, esenciales para futuras aplicaciones en tiempo real.

CONCLUSIONES

Este trabajo propone la utilización de redes neuronales MLP sin realimentación y entrenadas con métodos de segundo orden inspirados en la metodología back-propagation, para resolver el problema del flujo de potencia. La metodología fue aplicada a los sistemas de prueba Ward-Hale e IEEE-14 con resultados exitosos. Para ello se generaron 509 y 748 casos de flujos de potencia, respectivamente, simulando distintos niveles de carga, contingencias simples, salida de generadores, modificaciones en los taps y compensaciones shunt, entre otras.

El máximo error de tensión de todos los casos de entrenamiento y prueba para ambos sistemas de prueba resultó 0.88 % y el error promedio fue apenas 0.06 %. Esos errores son menores que otros valores reportados en la literatura existente [9, 6, 8], confirmando el potencial de una simple red neuronal MLP para aplicaciones en sistemas de potencia.

Una adecuada selección de las variables de entrada es importante para definir la arquitectura MLP más apropiada. Con la finalidad de minimizar la dimensión de los datos de entrada sólo se requiere incluir los elementos diagonales de la matriz admitancia de barra, con lo cual se obtienen resultados alentadores.

La combinación RNA+NR resultó 67.1% y 58.3% más rápida que el NR inicializado con flat start para los sistemas Ward-Hale e IEEE14, respectivamente. Este refinamiento NR no parece ser tan trascendental en aplicaciones de análisis de la seguridad estática.

AGRADECIMIENTOS

Los autores agradecen el apoyo de las instituciones brasileñas CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior) y CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico) para la realización de la presente investigación.

REFERENCIAS

1. Liacco T.E., "Enhancing power system security control", IEEE Computer Applications in Power, Vol.10, No.3, pp.38-41, July 1997.
2. Arrillaga J. and Arnold C.P., "Computer Analysis of Power Systems", John Wiley & Sons Ltd., 1990.
3. Stott B., "Review of load-flow calculation methods", IEEE Proceedings, Vol. 62, pp.916-929, 1974.
4. Van Amerongen R., "A general-purpose version of the fast decoupled load flow", IEEE Transactions on Power Systems, Vol.4, No.2, pp.760-770, May 1990.
5. Sobajic D.J. and Pao Y.H., "Artificial Neural-Net Based Dynamic Security Assessment for Electric Power Systems", IEEE Transactions on Power Systems, Vol.4, No.1, pp.220-226, Feb.1989.
6. El-Sharkawi M. and Niebur D., "Artificial Neural Networks with Applications to Power Systems", IEEE PES special publication 96 TP 112-0, 1996.
7. Haykin S., «Neural Networks: a comprehensive foundation», 2nd.ed., Prentice Hall, 1998.
8. Lo K.L., Peng L.J., Macqueen J.F, Ekwue A.O. and Cheng D.T.Y., "Fast Real Power Contingency Ranking Using a Counterpropagation Network", IEEE Transactions on Power Systems, Vol.13, No.4, pp.1259-1264, Nov. 1998.
9. Refaee J.A., Mohandes M. and Maghrabi H., "Radial Basis Function Networks for Contingency Analysis of Bulk Power Systems", IEEE Transactions on Power Systems, Vol.14, No.2, pp.772-778, May 1999.
10. Nguyen T.T., "Neural network load-flow", IEE Proceedings - Generation, Transmission and Distribution, Vol.142, No.1, pp.51-58, Jan.1995.
11. Paucar V.L., Morelato A.L. and Vuono E., "Training an ANN with the BFGS method for real-time identification of sinusoidal waveforms", Proceedings of the International Conference on Intelligent Systems Applications to Power Systems, ISAP, pp.193-196, Brazil, Apr. 1999.
12. Mansour Y., Chang A., Tamby J., Vaahedi E., Corns B. and El-Sharkawi M., "Large Scale Dynamic Security Screening and Ranking Using Neural Networks", IEEE Transactions on Power Systems, Vol. 12, No.2, pp.954-960, May 1997.