

Observabilidad Topológica para Estimación de Estado, Utilizando una Red Neuronal

J Robles-García¹, S B Barragán-Gómez², J L López Bonilla³

RESUMEN.- En la estimación robusta de estado es necesario establecer un espacio muestral de un conjunto de mediciones seleccionadas aleatoriamente. Lo que implica tratar de resolver un conjunto de ecuaciones que en muchas ocasiones son no observables topológica y numéricamente, esta es una característica natural del método. En este artículo se desarrolla un modelo de red neuronal para determinar la observabilidad topológica de un conjunto de mediciones de una red eléctrica. Se utilizan dos sistemas de pruebas, de cinco y el del IEEE-14 nodos con varias simulaciones, los resultados obtenidos con la red neuronal se comparan con los que se obtiene con el método de grafos. Se hace notar la diferencia del tiempo de cómputo en ambos métodos. Obteniéndose además la ventaja de entrenar la red neuronal con el umbral del sistema, con el cual la robustez numérica del sistema de ecuaciones a resolver es más estable.

PALABRAS CLAVES: Estimación Robusta de Estado, Observabilidad Topológica, Red Neuronal.

I. INTRODUCCIÓN

El resurgimiento de redes neuronales artificiales ha motivado a desarrollar nuevas tecnologías que permitan resolver problemas no lineales que requieren soluciones rápidas. Esto ha permitido resolver una gran variedad de problemas reales, en diferentes campos de la ingeniería. Por esta razón, aquí se pretende utilizar una red neuronal artificial para determinar la observabilidad topológica de un conjunto de mediciones de un sistema eléctrico de potencia, de manera rápida y confiable. Es importante mencionar que existen varios métodos convencionales para resolver este problema, en [1, 2] se encuentran reportados algunos de ellos.

En la estimación robusta de estado utilizando la mediana mínima cuadrada [7,8], se tiene la necesidad de resolver un cierto número de submuestras para poder obtener la estimación del vector de estado del sistema eléctrico bajo prueba. El número de submuestras a resolver depende de la dimensión de la red eléctrica, dichas submuestras son seleccionadas aleatoriamente del conjunto total de mediciones. Por lo que se debe determinar primeramente si la submuestra seleccionada es observable o no, antes de pasar a la fase de solución del sistema de ecuaciones correspondientes.

Este proceso es una característica natural de la estimación robusta, por consiguiente en esta etapa el tiempo de cómputo es considerable. Esto ha motivado a tratar de resolver dicho problema con una red neuronal. Los resultados de la red neuronal se comparan con el método de grafos para analizar la confiabilidad, así como las ventajas que éste presenta. Para desarrollar lo anterior se utiliza una red eléctrica de cinco y otra de catorce nodos.

II. REVISIÓN DE REDES NEURONALES ARTIFICIALES (RNA)

A. Características de una Red Neuronal Artificial

^{1,2,3} SEPI-ESIME-Zacatenco, Instituto Politécnico Nacional, Col. Lindavista, CP 07738 México DF
E-mail: jlopezb@ipn.mx

Existen varios artículos donde se reportan las tecnologías y características de una RNA, pero en [3,4] se encuentran ampliamente desarrolladas. Una característica importante de una Red Neuronal Artificial consiste en su habilidad de aprender. A diferencia de los métodos algorítmicos tradicionales en el cual se conocen de manera explícita en forma de reglas o ecuaciones, en cambio una RNA genera sus reglas y ecuaciones para resolver problemas, aprendiendo de ejemplos. Este aprendizaje o entrenamiento es análogo a la programación con métodos computacionales tradicionales y se logra a través de procesos adaptables.

B. Ventajas del cálculo neuronal

Las ventajas de las metodologías del cálculo neuronal sobre las convencionales [3,4], son:

- i.-* Rapidez de cálculo: esto se debe al paralelismo inherente en la estructura topológica y en la operación.
- ii.-* Habilidad de aprendizaje: entrenada por datos de simulación o de tiempo real del sistema.
- iii.-* Factores adaptables: los pesos de conexión de una red neuronal artificial pueden cambiar en el tiempo usando resultados actuales para mejorar su ejecución.
- iv.-* Manejo de datos: una RNA puede procesar volúmenes de tarjetas o datos en forma colectiva.
- v.-* Robustez: el paralelismo de una RNA provee una gran tolerancia a fallas debido a la representación distribuida y procesamiento de la información.

III. REDES NEURONALES ARTIFICIALES EN SISTEMAS DE POTENCIA

Se han realizado varios trabajos utilizando RNA para sistemas de potencia los cuales están reportados en [5]. En esta ocasión se pretende utilizar la red neuronal para determinar la observabilidad topológica de un sistema de potencia a partir de un conjunto de mediciones (mediciones de flujo de potencia activa y reactiva, voltajes e inyecciones de potencia activa y reactiva). Para resolver dicho problema se utiliza el modelo del perceptrón el cual se describe a continuación.

A. Perceptrón

En Redes Neuronales Artificiales el modelo del perceptrón es una herramienta que ha permitido resolver una gran variedad de problemas reales en distintas áreas del conocimiento, siempre y cuando los problemas se puedan representar por un perceptrón. Es importante mencionar que en una red neuronal existen dos problemas a resolver, la primera consiste en representar adecuadamente el modelo a simular para una función específica -con ello se determina el número de perceptrones a utilizar así como el número de capas ocultas- y la segunda consiste en entrenar la red para generar salidas precisas de acuerdo al vector de entrada.

En [3, 6] se puede encontrar el desarrollo de este modelo, aquí solo se representará el esquema de dicho método a utilizar, para el problema a resolver. En la figura 1 se presenta la red neuronal artificial del perceptrón, que consiste de una capa de entrada, una capa oculta y una capa de salida.

Los W_{ji} representan los pesos o ponderaciones de la red neuronal.

El perceptrón pertenece a las redes neuronales con entrenamiento no supervisado, es decir, los pesos son ajustados de acuerdo a las características de los datos o patrones de entrada. El entrenamiento consiste solamente de los vectores de entrada, esto es, aplicando un vector de una clase dada en la entrada se produce un vector de salida específico.

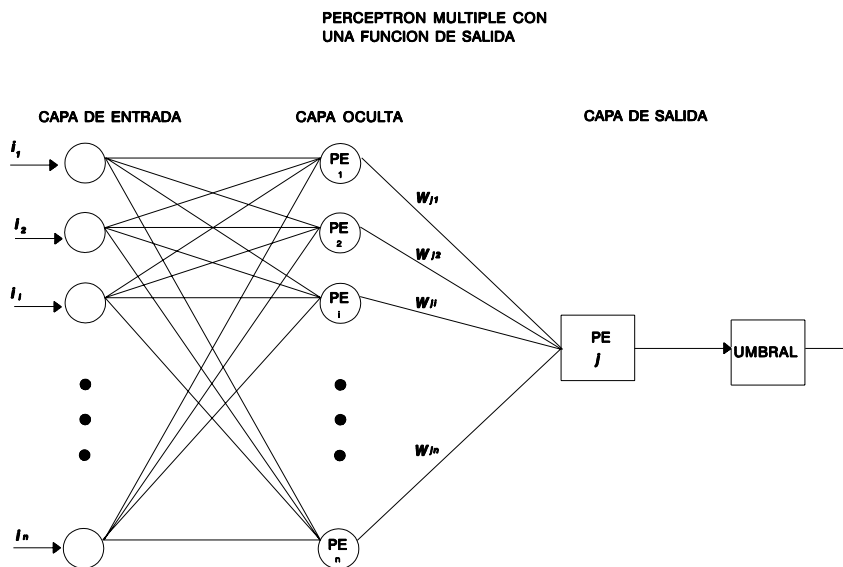


Figura 1. Perceptrón múltiple con una función de salida

B. Patrones de entrada

La observabilidad topológica se va a determinar en función de un conjunto de mediciones seleccionadas aleatoriamente en el sistema de potencia, las cuales consisten en :

- Mediciones de flujo de potencia activa y reactiva en líneas de transmisión.
- Mediciones de inyecciones de potencia activa y reactiva.
- Medición de voltaje

Los patrones de entrada se establecen según el tipo de medición que se tenga en el vector de mediciones, para un sistema de potencia bajo prueba. Así, para el caso de estudio se tienen cuatro clases de patrones de entrada:

i.- Si se tiene una medición de flujo de potencia activa y reactiva entonces el patrón de entrada activará las neuronas correspondientes al perceptrón de acuerdo al punto de medición. Por ejemplo, si tenemos una medición en la línea que existe entre los nodos 2 y 3 de la red eléctrica de la figura 2, localizado en el nodo 2 (2-3) el patrón de entrada se activaría de la forma como se muestra en la figura 3, donde un uno indica activación y un cero lo contrario.

ii.- Cuando se tiene una medición de voltaje solo se activará el perceptrón según el punto de medición, es decir, si tenemos una medición de voltaje en el nodo 1 (ver figura 2) obtenemos el patrón de entrada que se muestra en la figura 4.

iii.- El tercer patrón corresponde al generado por las inyecciones nodales de potencia activa y reactiva, aquí las neuronas activan al perceptrón de acuerdo al nodo que se esté midiendo, por ejemplo, si tenemos una inyección nodal en el nodo 3 (ver figura 2), entonces el patrón de entrada queda como se muestra en la figura 5.

iv.- Finalmente, el cuarto patrón de entrada corresponde a las características del conjunto de mediciones que se tienen y consiste en activar la neurona correspondiente al perceptrón. Si en el

perceptrón se tienen dos neuronas activados que son adyacentes a él entonces se activa dicha neurona. Esto se puede observar en la figura 6 donde se resalta la línea que representa la neurona que se activa debido a que existen dos neuronas adyacentes activadas en el perceptrón.




Figura 2. Sistema de prueba de 3 nodos




Figura 3. Patrón de entrada tipo 1




Figura 4. Patrón de entrada tipo 2




Figura 5. Patrón de entrada tipo 3




Figura 6. Patrón de entrada tipo 4

C. Capa oculta

Se entiende por capa oculta aquella que exista entre la capa de entrada y la capa de salida. En esta fase se determina el criterio de ponderación a seguir para que la red se entrene adecuadamente y a la vez genere salidas precisas de acuerdo al vector de entrenamiento. Cuando los pesos se pueden determinar adecuadamente, de acuerdo a las características de los datos de entrada, se logra disminuir en gran parte el tiempo de entrenamiento y por consiguiente el tiempo del proceso también es menor. La función que se propone en esta fase es la siguiente

$$f_i(x) = \begin{cases} 1 & \text{si } a_i > 0 \\ 0 & \text{si } a_i \leq 0 \end{cases} \tag{1}$$

A continuación se presentan los criterios para la ponderación de los lazos de los perceptrones:

D. Determinación de los pesos

1.- El perceptrón de la capa oculta asignará un peso de 0.5 a la neurona de salida si se encuentra activado una neurona adyacente en la capa de entrada. Este criterio está respaldado por el concepto de que una medición de flujo de potencia activa y reactiva solo determina la observabilidad del punto de medición.

2.- Si el perceptrón tiene activados dos neuronas adyacentes entonces el peso de la neurona de salida de este perceptrón es uno, este criterio es una consecuencia del concepto anterior, haciendo la aclaración de que el máximo valor de la ponderación es uno.

3.- Si el perceptrón tiene activado una neurona correspondiente a él, entonces la neurona de salida toma un peso de uno, esto implica que se trata de una medición de voltaje o una medición de inyección de potencia nodal.

Cuando el peso de las neuronas es 0.5 implica que es un nodo que tiene redundancia mínima, mientras que si el peso de la neurona toma el máximo valor, indica que tiene una robustez numérica mayor que el caso anterior. Esta característica permite de alguna manera determinar el umbral inicial de la red neuronal.

E. Umbral

Es la función objetivo de la red neuronal para determinar la salida para un vector de entrenamiento de entrada. Para el problema que se plantea resolver, en la salida se espera que la red neuronal indique si la red es observable o no, dado un vector de entrenamiento -El vector de entrenamiento consiste de un conjunto de mediciones seleccionados aleatoriamente-. El umbral que se propone utilizar para este caso es el que se obtiene de la ecuación (2).

$$um = 1 + nb / 2 \quad (2)$$

donde, nb es el número de nodos. Con el umbral inicial se determinan qué vectores de entrenamiento seleccionados aleatoriamente son observables topológicamente. Estos resultados se pueden comparar con un método convencional para verificar los resultados.

La red neuronal que se propone en este trabajo consiste en que el entrenamiento se realiza con los vectores de entrada. Así como entrenar la red neuronal con el umbral, esto consiste en utilizar inicialmente el umbral que se obtiene de la ecuación (2) y posteriormente se modifica para mejorar la robustez numérica del sistema de ecuaciones correspondiente a la red eléctrica que resulte observable. Logrando con lo anterior que la red neuronal genere sistemas topológica y numéricamente observables, con lo cual se mejora la eficiencia de la estimación robusta de estado.

F. Capa de salida

En esta fase se determina si el vector de entrenamiento es observable topológicamente o no, la función que se propone consiste en:

$$S(x) = \begin{cases} 1 & \text{si } b \geq um \\ 0 & \text{si } b \leq um \end{cases} \quad (3)$$

donde :

$$b = \sum_{i=1}^n (f_i(x))(ws_i) \tag{4}$$

En la ecuación (3) se puede observar que en la salida de la red neuronal se tienen unos o ceros, estableciendo que un uno indica que el vector de entrada es observable topológicamente.

IV. PLANTEAMIENTO DEL PROBLEMA

El modelo de la red neuronal mencionada anteriormente se pretende utilizar para obtener un conjunto de mediciones que sean observables topológicamente, los cuales se utilizarán en la estimación robusta de estado. En la figura 7 se presenta un esquema de la estimación robusta, donde se observa la aplicación de la red neuronal, que consiste en lo siguiente:

- 1.- En el vector de entrada se obtiene un conjunto de mediciones seleccionado aleatoriamente.
- 2.- La red neuronal determina si este conjunto de mediciones es observable topológicamente.
- 3.- Si dicho conjunto es observable topológica y numéricamente entonces se resuelve el sistema de ecuaciones correspondiente y se almacena la solución obtenida
- 4.- Después del punto anterior se regresa al punto 1 y el proceso se termina cuando se cumpla la condición del número de submuestras a resolver.

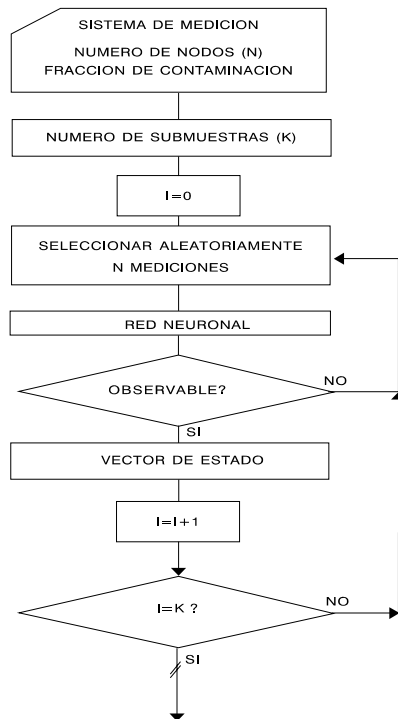


Figura 7. Diagrama de flujo parcial para el método de mediana mínima cuadrada.

V. ASPECTOS COMPUTACIONALES

El tamaño de cada vector en la capa oculta está determinado por el número de nodos del sistema eléctrico, los vectores de la capa oculta se representan por una matriz A , donde cada fila corresponde al vector de entrada en la capa oculta. La matriz A resulta ser cuadrada y de orden $n \times n$, donde n representa el número de nodos, la matriz de ponderación W tiene la misma estructura y orden que A .

Lo anterior puede llegar a ser una limitante cuando el tamaño del sistema de potencia es relativamente grande, cuando este problema se presenta es recomendable realizar las operaciones en forma vectorial, lo anterior repercute en un mayor tiempo de cómputo del proceso, sin embargo, este problema se resuelve utilizando una computadora que sea capaz de realizar operaciones por vectores o utilizando procesamiento en paralelo.

VI. CASOS DE ESTUDIO

Se presentan cuatro casos de estudio para determinar la observabilidad topológica del sistema eléctrico, utilizando la red neuronal artificial antes mencionada, partiendo de un conjunto de mediciones seleccionadas aleatoriamente.

i.- El primer estudio consiste en un sistema eléctrico de cinco nodos y su diagrama unifilar se muestra en la figura 8. En este caso la salida de la red neuronal se compara con el resultado que se obtiene utilizando el método de Echelon. En la Tabla 1 se presentan de manera resumida los resultados que se obtienen por ambos métodos.

sistema de prueba de cinco nodos




Figura 8. Esquema de medición del sistema de 5 nodos

Tabla 1. Comparación de los resultados de la red neuronal y el método de Echelon: con umbral fijo

No. de subm./umbral	Solución de la red neuronal artificial	Resultado del método de grafos	Resultado de convergencia numérica	Conjunto de mediciones seleccionadas en forma aleatoria
1/3.0	observable	observable	converge	{2-1; 1-3; 3-4}O; {2}v
2/3.0	observable	observable	converge	{2-1; 3-4}O; {2}v; {4; 5}■
3/3.0	observable	observable	no converge	{1-2; 1-3; 2-5; 3-4}O; {2}v
4/3.0	no observable	observable	no converge	{1-2; 3-1; 2-4; 4-5}O; {2}v
5/3.0	observable	observable	converge	{2-1; 2-5}O; {2}v; {4; 5}■
6/3.0	observable	observable	converge	{2-1; 2-4; 3-4}O; {2}v; {5}■
7/3.0	no observable	observable	no converge	{1-3; 3-2; 2-5; 4-5}O; {2}v
8/3.0	observable	observable	no converge	{2-1; 3-2; 3-4}O; {2}v; {4}■
9/3.0	observable	observable	converge	{1-2; 3-2; 2-4}O; {2}v; {5}■

O.- Mediciones de flujo de potencia activa y reactiva; v.- Medición de voltaje; ■.- Medición de potencia nodal

ii.- En este segundo estudio se utiliza la misma red eléctrica del punto anterior. Se considera el entrenamiento del umbral durante el proceso para analizar el comportamiento de la red neuronal y comparar con los resultados que se obtienen con el método de grafos, esto se puede observar en la Tabla 2.

Tabla 2. Comparación de resultados de la red neuronal y el método de Echelon: con entrenamiento del umbral

No. de subm./umbral	Solución de la red neuronal artificial	Resultado del método de grafos	Resultado de convergencia numérica	Conjunto de mediciones seleccionadas en forma aleatoria
1/3.0	observable	observable	converge	{2-1; 1-3; 3-4}0; {2}v
2/4.0	observable	observable	converge	{2-1; 3-4}0; {2}v; {4; 5}■
3/4.0	no observable	observable	no converge	{1-2; 1-3; 2-5; 3-4}0; {2}v
4/4.0	no observable	observable	no converge	{1-2; 3-1; 2-4; 4-5}0; {2}v
5/4.0	observable	observable	converge	{2-1; 2-5}0; {2}v; {4; 5}■
6/4.0	no observable	observable	no converge	{2-1; 3-1; 2-4; 4-5}0; {2}v
7/4.0	observable	observable	converge	{2-1; 2-4; 3-4}0; {2}v; {5}■
8/3.5	no observable	observable	converge	{1-2; 3-2; 2-4}0; {2}v; {5}■

iii.- Este estudio consiste en un sistema eléctrico de catorce nodos y su esquema de medición se muestra en la figura 9. En este caso la salida de la red neuronal se compara con el resultado que se obtiene utilizando el método de grafos. En la Tabla 3 se presentan de manera resumida los resultados que se obtienen por ambos métodos.

Tabla 3. Comparación de los resultados de la red neuronal y el método de Echelon: con umbral fijo

No. de subm./umbral	Solución de la red neuronal	Método de grafos	Resultado de convergencia numérica	Conjunto de mediciones seleccionadas en forma aleatoria
1/7.5	observable	observable	converge	{1-2; 4-3; 5-2; 5-4; 10-11; 13-12; 14-9}0 {6}v; {4; 6; 10; 14; 7; 11}■
2/7.5	observable	observable	converge	{1-2; 2-4; 5-1; 6-11; 7-8; 9-7; 13-12}0 {6}v; {4; 10; 12; 13; 7; 11}■
3/7.5	observable	observable	converge	{1-2; 2-4; 3-4; 5-6; 7-8; 10-11; 13-12; 14-9}0 {3}v; {4; 10; 12; 7; 11}■
4/7.5	observable	observable	converge	{1-2; 4-3; 5-1; 5-10; 10-9; 13-6; 14-9}0 {6}v; {6; 8; 12; 7; 11}■
5/7.5	observable	observable	converge	{1-2; 3-4; 4-7; 5-2; 9-4; 10-9; 13-12}0 {6}v; {4; 10; 12; 14; 7; 11}■
6/7.5	observable	observable	converge	{1-2; 4-3; 4-7; 5-2; 9-4; 10-11; 13-6; 14-9}0 {3}v; {4; 12; 14; 7; 11}■
7/7.5	observable	observable	converge	{1-2; 3-2; 5-1; 5-4; 9-7; 13-12; 14-9}0 {3}v; {4; 10; 12; 14; 7; 11}■
8/7.5	observable	observable	converge	{2-4; 4-3; 5-1; 5-2; 5-6; 7-8; 10-9; 13-12; 13-14}0 {2}v; {10; 12; 7; 11}■
9/7.5	observable	observable	converge	{1-2; 4-3; 4-7; 5-2; 8-7; 13-6}0 {2}v; {4; 6; 10; 12; 13; 7; 11}■
10/7.5	observable	observable	converge	{1-2; 3-4; 5-1; 5-4; 9-4; 10-9; 13-6; 13-12}0 {6}v; {6; 8; 13; 7; 11}■
11/7.5	observable	observable	converge	{1-2; 4-3; 5-2; 5-2; 5-4; 9-4; 13-12}0 {6}v; {6; 8; 10; 12; 13; 7; 11}■

iv.- En este último estudio se utiliza la misma red eléctrica del punto anterior. Se considera el entrenamiento del umbral durante el proceso para analizar el comportamiento de la red neuronal y

comparar con los resultados que se obtienen con el método de grafos, esto se puede observar en la Tabla 4.

Tabla 4. Comparación de los resultados de la red neuronal y el método de Echelon: con entrenamiento del umbral

No. de subm./ umbral	Solución de la red neuronal	Método de grafos	Resultado de convergencia numérica	Conjunto de mediciones seleccionadas en forma aleatoria
1/7.5	observable	observable	converge	{1-2; 4-3; 5-2; 5-4; 10-11; 13-12; 14-9}O {6}v; {4; 6; 10; 14; 7; 11}■
2/8.0	observable	observable	converge	{1-2; 2-4; 5-1; 6-11; 7-8; 9-7; 13-12}O {6}v; {4; 10; 12; 13; 7; 11}■
3/8.5	observable	observable	converge	{1-2; 2-4; 3-4; 5-6; 7-8; 10-11; 13-12; 14-9}O {3}v; {4; 10; 12; 7; 11}■
4/9.0	observable	observable	converge	{1-2; 4-3; 5-1; 5-10; 10-9; 13-6; 14-9; }O {6}v; {6; 8; 12; 7; 11}■
5/9.0	observable	observable	converge	{1-2; 3-4; 4-7; 5-2; 9-4; 10-9; 13-12}O {6}v; {4; 10; 12; 14; 7; 11}■
6/9.5	observable	observable	converge	{1-2; 4-3; 4-7; 5-2; 9-4; 10-11; 13-6; 14-9}O {3}v; {4; 12; 14; 7; 11}■
7/9.5	observable	observable	converge	{1-2; 3-2; 5-1; 5-4; 9-7; 13-12; 14-9}O {3}v; {4; 10; 12; 14; 7; 11}■
8/10.0	observable	observable	converge	{2-4; 4-3; 5-1; 5-2; 5-6; 7-8; 10-9; 13-12; 13-14}O {2}v; {10; 12; 7; 11}■
9/10.0	observable	observable	converge	{1-2; 4-3; 4-7; 5-2; 8-7; 13-6}O {2}v; {4; 6; 10; 12; 13; 7; 11}■
10/10.5	observable	observable	converge	{1-2; 3-4; 5-1; 5-4; 9-4; 10-9; 13-6; 13-12}O {6}v; {6; 8; 13; 7; 11}■
11/10.5	observable	observable	converge	{1-2; 4-3; 5-2; 5-2; 5-4; 9-4; 13-12}O {6}v; {6; 8; 10; 12; 13; 7; 11}■

O.- Mediciones de flujo de potencia activa y reactiva; v.- Medición de voltaje; ■.- Medición de potencia nodal

A. Análisis de resultados

En el primer estudio (Tabla 1) se puede hacer notar que en las submuestras 1,2,5,6 y 9 el resultado de la red neuronal artificial coincide con el método de grafos, que resultan ser observables y se obtiene la solución. Sin embargo, en las submuestras 3 y 8 el resultado de ambos métodos es observable, pero no convergen, esto indica que los sistemas de ecuaciones correspondiente son no observables numéricamente. Analizando el resultado de las submuestras 4 y 7 se observa que en los dos casos la red neuronal determina que son no observables, mientras que el método de grafos determina lo contrario. Al tratar de resolver dichos sistemas de ecuaciones estos no convergen debido a que no son no observables numéricamente. Lo anterior demuestra que el umbral determinado por la ecuación (1) es adecuado.

Considerando los resultados del segundo estudio que se obtienen utilizando la misma semilla de inicialización del primer estudio (Tabla 2), se observa que en las dos primeras submuestras y la quinta el resultado de ambos métodos son iguales, los cuales son observables; Analizando los resultados para las submuestras 3, 4 y 6 se observa que en dichos casos la red neuronal determina que son no observables, sin embargo, el método de grafos determina lo contrario, estos resultados son similares al último punto que se analizó en el primer estudio. Por lo que a continuación se analizan los resultados de las submuestras 7 y 8, donde se observa que el resultado de la red neuronal es no observable, mientras que el método de grafos determina lo contrario. Si se pasa a la fase de solución de ambas submuestras estos convergen, pero sus soluciones difieren comparadas con las que se obtienen con las otras submuestras, en la Tabla 5 se presentan estos resultados.

Tabla 5. Resultados de los voltajes obtenidos en las submuestras de las mediciones

VOLTAJES ESTIMADOS

submuestra 1 en forma polar			submuestra 2 en forma polar			submuestra 5 en forma polar			submuestra 7 en forma polar			submuestra 8 en forma polar		
nodo	voltaje	ángulo	nodo	voltaje	ángulo	nodo	voltaje	ángulo	nodo	voltaje	ángulo	nodo	voltaje	ángulo
1	1.02988	.00000	1	1.02988	.00000	1	1.02988	.00000	1	1.02988	.00000	1	1.02988	.00000
2	1.04250	2.88892	2	1.04250	2.88892	2	1.04250	2.88892	2	1.04250	2.88892	2	1.00654	-3.00397
3	1.00664	-2.25413	3	1.00523	-2.41289	3	1.00664	-2.19605	3	1.00679	-2.86621	3	1.00647	-2.29775
4	1.00599	-2.58906	4	1.00458	-2.74878	4	1.00600	-2.53097	4	1.00580	-3.10926	4	1.00600	-2.53097
5	.99983	-3.43852	5	.99932	-3.49260	5	.99985	-3.41940	5	.99966	-3.60988	5	.99985	-3.41940

En el tercer estudio (Tabla 3) se puede hacer notar que todas las submuestras coinciden con el resultado de la red neuronal artificial y el método de grafos, que resultan ser observables y se obtiene la solución. Lo anterior demuestra que el umbral determinado por la ecuación (1) es adecuado, es importante mencionar que si durante el proceso de estimación robusta de estado se considera el resultado de la red neuronal, el tiempo de cómputo disminuye. Esto se debe porque no se trataría de resolver un conjunto de ecuaciones que carece de robustez numérica.

Considerando los resultados del cuarto estudio que se obtienen utilizando la misma semilla de inicialización del primer estudio (Tabla 4). El resultado de ambos métodos son iguales en todas las submuestras, los cuales son observables. Sin embargo, es de vital importancia mencionar que durante el proceso de determinación de la observabilidad topológica, muchas submuestras no pasan a la fase de solución debido a que no superan el umbral establecido por la red neuronal. De los resultados anteriores se puede hacer notar que cuando se incluye el entrenamiento del umbral en la red neuronal, las soluciones que se obtienen son aquellas que poseen una mejor robustez numérica.

Es de esperar un menor tiempo de cómputo en la determinación de topología utilizando una red neuronal, que el utilizado por el método de grafos, debido a que se utilizan solamente vectores y operaciones elementales. Mientras que en el caso de grafos, para sistemas grandes es necesario utilizar vectores encadenados y simular las operaciones.

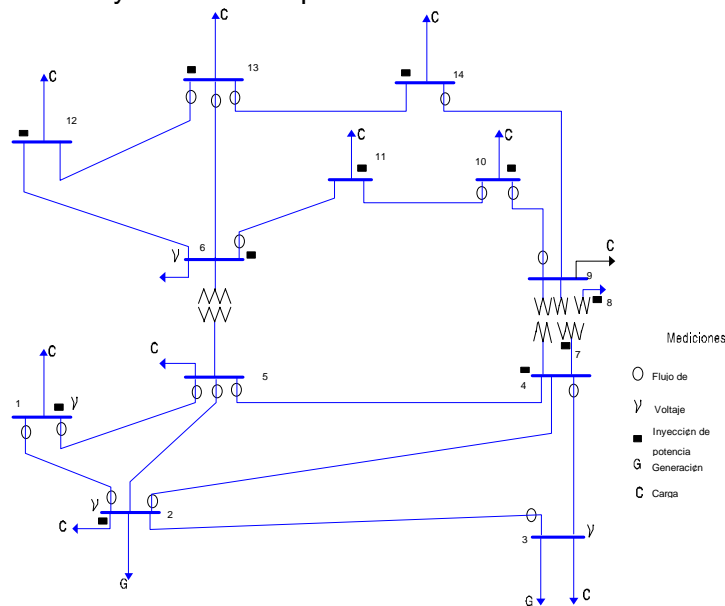


Figura 9. Esquema de medición del sistema de 14 nodos

VII. CONCLUSIONES

Cuando los pesos se pueden determinar adecuadamente, de acuerdo a las características de los datos de entrada, se logra disminuir en gran parte el tiempo de entrenamiento, y por consiguiente el tiempo del proceso también es menor.

De los resultados presentados se demuestra que el umbral determinado por la ecuación (1) es adecuado. Es importante mencionar que si durante el proceso de estimación robusta de estado se considera el resultado de la red neuronal, el proceso es más eficiente y ventajoso. Esto se debe a que no se trataría de resolver un conjunto de ecuaciones que carece de robustez numérica.

De los resultados de las Tablas 2 y 4 se puede concluir que, cuando se incluye el entrenamiento del umbral en la red neuronal, las soluciones que se obtienen son aquellas que poseen la mejor robustez numérica.

REFERENCIAS

- [1] Monticelli A., F. F. Wu, "Network Observability: Theory", IEEE Transactions on Power Apparatus and systems, Vol. Pas-104, No.5, May 1985.
- [2] Mori, H., S. Tsuzuki, "A Fast Method for Topological Observability Analysis Using a Minimum Spanning Tree Technique", IEEE Transactions on Power Apparatus and systems, Vol. 6, No.2, May 1991.
- [3] Lau C., B. Widrow, "Special Issue on Neural Networks I & II", IEEE Proceeding, Vol. 78, No.9-10, Sept-Oct 1990, pp. 1411-1675
- [4] Computer Applications, "Working with Neural Networks", IEEE Spectrum, July 1993.
- [5] El-sharkawi M. A., R.J. Marks II, Eds. "Proc. of the First International Forum on Applications of Neural Networks to Power Systems", Seattle, July 1991
- [6] Hertz J., A. Krosh, "Introduction to the theory of Neural Computation", Addison-Wesley Publishing Company 1991
- [7] Romero D., J. Robles, "Identificación de Puntos de Apalancamiento en Estimación Robusta de Estado Utilizando la Distancia de Mahalanobis", Octava Reunión de Verano de Sistemas de Potencia, IEEE Sección México, Julio de 1995.
- [8] Romero D., J. Robles, "Network Topology Error Identification in Robust State Estimation for Power Systems", 2nd IFAC Symposium on Control on Power Plants and Power Systems, Cancún, México, Dec 1995.