

**ESTRATEGIA DE IDENTIFICACIÓN DINÁMICA NO LINEAL BASADA EN  
NARX PARA FUENTES DE GENERACIÓN DISTRIBUIDA ACOPLADAS  
ELECTRÓNICAMENTE A MICRO – REDES AC/DC.**



**UNIVERSIDAD POLITÉCNICA SALESIANA  
SEDE QUITO**

**CARRERA:  
INGENIERÍA ELÉCTRICA**

**Trabajo de titulación previo a la obtención del título de:  
INGENIERO ELÉCTRICO**

**TEMA:  
ESTRATEGIA DE IDENTIFICACIÓN DINÁMICA NO LINEAL BASADA EN  
NARX PARA FUENTES DE GENERACIÓN DISTRIBUIDA ACOPLADAS  
ELECTRÓNICAMENTE A MICRO – REDES AC/DC.**

**AUTOR:  
FRANCISCO ALEJANDRO URGILES NAVARRETE**

**TUTOR:  
LEONY ORTIZ MATOS**

**Quito, julio del 2020**

Francisco Alejandro Urgiles Navarrete

**ESTRATEGIA DE IDENTIFICACIÓN DINÁMICA NO LINEAL BASADA EN NARX PARA FUENTES DE GENERACIÓN DISTRIBUIDA ACOPLADAS ELECTRÓNICAMENTE A MICRO – REDES AC/DC.**

Universidad Politécnica Salesiana, Quito-Ecuador 2020  
Ingeniería Eléctrica

Breve reseña historia e información de contacto:



**Francisco Alejandro Urgiles Navarrete** (Y'1992-M'07). Realizó sus estudios secundarios en el “Colegio Técnico Experimental de Aviación Civil”, se graduó de bachiller en “Ciencias Generales”. Egresado de la Carrera de Ingeniería Eléctrica de la Universidad Politécnica Salesiana. Su trabajo se basa en la Estrategia de identificación dinámica no lineal basada en NARX para fuentes de generación distribuida acopladas electrónicamente a Micro – redes AC/DC.

[furgilesn@est.ups.edu.ec](mailto:furgilesn@est.ups.edu.ec)

Dirigido por:



**Leony Ortíz Matos** (Y'1982). Recibió el título de MSc. e Ingeniería en Automática por el Instituto Superior Politécnico Julio Antonio Mella (ISPJAM) de la Universidad de Oriente, Cuba. Actualmente se encuentra estudiando para obtener su título de Doctor en Ingeniería en la Universidad Pontificia Bolivariana-Colombia-Medellín, es miembro del Grupo de Investigación en Redes Eléctricas Inteligentes (GIREI). Forma parte del equipo académico de la carrera de Ingeniería Eléctrica de Universidad Politécnica Salesiana Quito-Ecuador. Sus principales intereses de investigación Automatización y Control, Control robusto y Control Tolerante a Fallos, Micro-redes Eléctricas Inteligentes híbrida, CA/CC.

[lortizm@ups.edu.ec](mailto:lortizm@ups.edu.ec)

**Todos los derechos reservados:**

Queda prohibida, salvo excepción prevista en la ley, cualquier forma de reproducción, distribución, comunicación pública y transformación de esta obra para fines comerciales, sin contar con la autorización de los titulares de propiedad intelectual. La infracción de los derechos mencionados puede ser constitutiva de delito contra la propiedad intelectual. Se permite la libre difusión de este texto con fines académicos o investigativos por cualquier medio, con la debida notificación a los autores.

DERECHOS RESERVADOS  
©2020 Universidad Politécnica Salesiana  
QUITO-ECUADOR

## **DECLARATORIA DE COAUTORÍA DEL DOCENTE TUTOR/A**

Yo, Leony Ortiz Matos declaro que bajo mi dirección y asesoría fue desarrollado el trabajo de titulación *ESTRATEGIA DE IDENTIFICACIÓN DINÁMICA NO LINEAL BASADA EN NARX PARA FUENTES DE GENERACIÓN DISTRIBUIDA ACOPLADAS ELECTRÓNICAMENTE A MICRO – REDES AC/DC* realizado por Francisco Alejandro Urgiles Navarrete, obteniendo un producto que cumple con todos los requisitos estipulados por la Universidad Politécnica Salesiana para ser considerados como trabajo final de titulación.

Quito, Julio 2020



.....

Leony Ortiz Matos

Cédula de identidad: 1718002221

## **CESIÓN DE DERECHOS DE AUTOR**

Yo Francisco Alejandro Urgiles Navarrete, con documento de identificación N° 1718162223, manifiesto mi voluntad y cedo a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que soy autor del trabajo de titulación intitulado: *“ESTRATEGIA DE IDENTIFICACIÓN DINÁMICA NO LINEAL BASADA EN NARX PARA FUENTES DE GENERACIÓN DISTRIBUIDA ACOPLADAS ELECTRÓNICAMENTE A MICRO – REDES AC/DC”*, mismo que ha sido desarrollado para optar por el título de: Ingeniero Eléctrico, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En aplicación a lo determinado en la Ley de Propiedad Intelectual, en mi condición de autor me reservo los derechos morales de la obra antes citada. En concordancia, suscribo este documento en el momento que hago entrega del trabajo final en formato digital a la Biblioteca de la Universidad Politécnica Salesiana.



.....  
Nombre: Francisco Alejandro Urgiles Navarrete  
Cédula: 1718162223  
Fecha: Quito, Julio 2020

## 1. INDICE GENERAL

1. Introducción. ....	2
2. Micro – red Eléctrica. ....	3
2.1 Arquitectura de las Micro – redes. ....	3
2.2 Fuentes de Generación Distribuida en las Micro - redes. ....	4
3. Problema de Identificación de Sistemas No lineales. ....	5
3.1 Redes Neuronales Artificiales. ....	6
3.2 Red Neuronal Autorregresiva no Lineal con entradas Exógenas (NARX). ....	6
4. Planteamiento del problema. ....	8
4.1 Modelo Matemático NARX. ....	9
5. Caso de Estudio. ....	10
6.1 Datos obtenidos para todos los puntos de operación en la barra AC. ....	10
5.1.1 Identificación y análisis de los puntos de operación del caso 1. ....	11
5.1.2 Identificación y análisis de los puntos de operación del caso 2. ....	11
6. Análisis de resultados y validación del modelo . ....	12
6.1 Análisis del Modelo NARX en el caso 1. ....	12
6.1.1 Análisis y Validación de los puntos de operación de la MR AC del caso 1. ....	13
7.2 Validación de resultados del modelo NARX en el caso 2. ....	15
7.2.1 Análisis e Identificación de los puntos de operación de la MR AC caso 2. ....	16
7. Conclusiones. ....	18
8. Trabajos Futuros. ....	18
9. Referencias. ....	18
10. Estado del Arte. ....	22
10.1 Matriz de Estado del Arte. ....	22
10.2 Resumen de Indicadores. ....	26

## 2. INDICE DE FIGURAS

Figura 1. Modelo de la Micro - red AC/DC, asociada a una Red Neuronal. ....	4
Figura 2. Estructura de la Micro – red básica. ....	4
Figura 3. Modelo de generación distribuida. ....	5
Figura 4. Red Neuronal Artificial. ....	6
Figura 5. Modelo red neuronal NARX. ....	7
Figura 6. Arquitectura de entradas en Serie y Paralelo del modelo NARX. ....	7
Figura 7. Esquema del caso de Estudio MR AC/DC. ....	11
Figura 8. Datos de voltaje de la barra AC de la MR ....	11
Figura 9. Datos de corriente de la barra AC de la MR ....	11
Figura 10. Resultados observados de la corriente en la barra AC de la MR ....	12
Figura 11. Resultados observados del voltaje en la barra AC de la MR ....	12
Figura 12. Estructura de la red neuronal caso 1. ....	13
Figura 13. Corriente del modelo y puntos de operación, en la fase de validación. ....	14
Figura 14. Voltaje del modelo y puntos de operación, en la fase de validación. ....	14

Figura 15. Error de identificación de voltaje.....	15
Figura 16. Error de identificación de corriente.....	15
Figura 17. Estructura de la red neuronal caso 2. ....	15
Figura 18. Voltaje del modelo y validación del sistema de identificación.....	16
Figura 19. Corriente del modelo y validación del sistema de identificación. ....	17
Figura 20. Identificación de errores de Voltaje. ....	17
Figura 21. Identificación de errores de Corriente.....	17

### **3. INDICE DE TABLAS**

Tabla 1. Variables del Algoritmo .....	9
Tabla 2. Funciones del Algoritmo. ....	9
Tabla 3. Algoritmo NARX.....	9

# **ESTRATEGIA DE IDENTIFICACIÓN DINÁMICA NO LINEAL BASADA EN NARX PARA FUENTES DE GENERACIÓN DISTRIBUIDA ACOPLADAS ELECTRÓNICAMENTE A MICRO – REDES AC/DC.**

## **Resumen**

En el presente artículo, se propone un algoritmo para la identificación dinámica no lineal de fuentes de generación distribuidas acopladas electrónicamente a Micro-redes (MRs) eléctricas híbridas en AC/DC. El algoritmo propuesto aplica herramientas de identificación de sistemas por NARX para obtener un modelo no lineal de la planta en estudio. Los resultados obtenidos del modelo son validados mediante la observación de la respuesta dinámica de las salidas (V y I) obtenidas. La gran similitud entre los datos obtenidos y la aplicación del modelo NARX confirma, que el algoritmo propuesto servirá para la obtención de modelos no lineales de las fuentes de generación distribuidas asociadas las MRs en AC/DC. Se verifica y analiza los resultados mediante simulación digital en Matlab.

**Palabras Clave:** Sistemas no lineales, Micro-redes Híbridas AC/DC, Generación distribuida, Identificación de sistemas dinámicos, Modelo NARX.

## **Abstract**

In this article, is proposed an algorithm for the non linear dynamic identification of distibuted generation sources coupled electronically to Microgrids (MRs) electrical hybrid AC/DC . The proposed algorithm applies system identification tools by NARX to obtain a non-linear model of the plant under study. The results obtained from the model are validated by observing the dynamic response of the outputs (V and I) obtained. The great similarity between the data obtained and the application of the NARX model confirms that the proposed algorithm will serve to obtain non linear models of the distributed generation sources associated MRs in AC / DC. Are verified and analyzed the results by a digital simulation in Matlab.

**Keywords:** Non-linear System, AC/DC Hybrid Microgrid, Distributed Generation, Dynamic System Identification, NARX Model.

## 1. Introducción.

El aumento de la carga en la red de transmisión se ha incrementado a un ritmo apresurado, ya que esto se debe al aumento de consumidores. Por lo cual se dificulta la expansión de la red de transmisión, también al alto costo económico de inversión. Por ende el estudio de las Micro - redes (MRs) han entrado en auge en los últimos 10 años, se han desarrollado gracias a su bajo costo económico y su gran adaptación al sistema, por lo cual son más viables [1]. El estudio de las MRs adquirieron importancia en los últimos años ya que permiten una mejor capacidad de recuperación urbana y resiliencia en los Sistemas de Energía Eléctrica. Además, constituye uno de los conceptos emergentes para la transformación de las redes de transmisión, por las MRs las cuales facilitaran los servicios de generación, transmisión, distribución y la movilidad eléctrica [2], [3]. Comprender las dinámicas de las MR y usar metodologías de modelado apropiadas, busca la forma de resolver, los modelos convencionales de las Fuentes de Generación Distribuida (GD) [2], [4]. Dependiendo de la configuración, tipo y componentes, la dinámica de la MRs puede cambiar y resolver diferentes problemas en los sistemas de energía eléctrica [2], [5]. En los estudios recientes, se tiene claro que las MRs obtendrá un modelo de trabajo sobre los sistemas de energía eléctrica. Lo cual se convertirá paulatinamente, en mejores modelos para lugares aislados como también para sitios interconectados al sistema nacional de electricidad y otros estudios importantes [6]–[9]. Por lo tanto, es necesario realizar un estudio exhaustivo de las condiciones de oscilación de las MRs, debido a las variaciones de ganancia para garantizar el funcionamiento estable [10]. Hoy en día las fuentes de GD son parte de estudios y se están integrando a temas

como la Identificación de Sistemas para mejorar los funcionamientos y mejorar la estabilidad del sistema de electricidad.

En algunos escenarios, los investigadores tienen un modelo de un sistema para su análisis y para el control de los sistemas, ya que la gran mayoría de los métodos de diseño se basan en parámetros o diseños obtenidos [4], [11]. Pero algunos investigadores modelan prototipos, a partir de algún conocimiento previo sobre el proceso de funcionamiento o sobre un proceso experimental, a esto se lo define como Identificación de Sistemas [12]. Estos modelos con características dinámicas desconocidas, son no lineales y complejos de obtenerlos [13].

En consecuencia los investigadores han creado un campo de investigación amplio, en donde básicamente son conjuntos de métodos estadísticos y estocásticos, los cuales encuentran un modelo matemático, para un sistema dinámico no lineal que tiene un comportamiento similar a un sistema desconocido, como caja negra, que describe el comportamiento de la MRs, al inicio del análisis de las señales [4], [11], [14].

En este artículo se utilizara una estrategia a través de la utilización de un modelo, auto-regresivo no lineal con entradas exógenas (NARX), como herramienta para modelar las fuentes de GD acopladas a las MR AC/DC [15].

Este modelo permitirá la identificación sistemas dinámicos no lineales en las fuentes de GD, las cuales están acopladas a la MR en AC/DC por medio de convertidores electrónicos de potencia y sistemas de batería BEES. Dicho conjunto de fuentes de GD operara en condiciones normales, sin contingencias y en modo isla.

La validación del algoritmo y resultados se los realizará en el entorno de Matlab-Simulink.

Para una mejor revisión del trabajo propuesto se lo ha dividido en varias

partes: en el capítulo dos: MRs eléctrica, donde se explica de las características de la MR y las arquitecturas de las MRs. En el capítulo 3 se discutirá sobre las fuentes de generación distribuida (GD) en las MRs. En el capítulo 4 se dará una descripción de la Identificación de sistemas y del algoritmo NARX utilizados en el trabajo. En el capítulo 5 se discute sobre el planteamiento del problema y la resolución que se va a dar con el algoritmo NARX. El capítulo 6 se describe los casos de estudio para el artículo. El capítulo 7 está compuesto por los resultados obtenidos del análisis del modelo propuesto. Y en los capítulos 8 y 9 se comenta sobre investigaciones futuras y las conclusiones del trabajo.

## **2. Micro – red Eléctrica.**

Hoy en día los investigadores, han determinado que las MR se la puede modelar como una red de unidades generadoras de energía, las cuales son capaces de suministrar energía eléctrica a un área aislada, a una industria o a un sitio comercial [2], [16].

En un futuro muy cercano, las MR serán eléctricamente independientes y una alternativa viable para el desarrollo, las fuentes de GD, lo cual disminuirá que se utilicen fuentes de combustible fósil y que serán cambiadas con fuentes renovables las cuales no tendrán ningún impacto ambiental. Debido a su dinámica acelerada y tiempo de respuesta corto, mencionan los investigadores que esto es un desafío, para mejorar las MRs. Las MRs deben ser robustas para proteger el sistema de energía y así puedan controlar voltaje, corriente, frecuencia y proteger la red principal ante fallas del sistema [2], [17].

Usando las MR se puede lograr en las fuentes de GD, una mejor fiabilidad de las fuentes de alimentación, de igual forma el aumento de la eficiencia energética. Algo interesante es el almacenamiento de energía en los sistemas de baterías. Se espera que en el futuro, las MRs ofrezcan un intercambio de datos, por lo tanto el análisis dinámico de la MR sea un punto clave para organizar y garantizar el funcionamiento correcto y estable de una MRs [2], [16], [17].

### **2.1 Arquitectura de las Micro – redes.**

Como se muestra en la Figura 1, las MR son capaces de tener conectados a todos sus componentes, de consumo como también de equipos de generación, abastecimiento los cuales tendrán una autonomía completa en el sistema de conexión [18]. Los investigadores mencionan que las MR operan en bajo y medio voltaje y se puede tener entre 2 o más fuentes de generación. Las MR en modo de operación puede funcionar en modo aislado de la red autónoma o conectada a la misma [2][19]. Habiendo dicho esto, La MR están compuestas por diferentes sistemas y subsistemas para su buen funcionamiento, los autores consideran cuatro componentes claves para la operación correcta: Generación, Consumidor, almacenamiento y estructura.

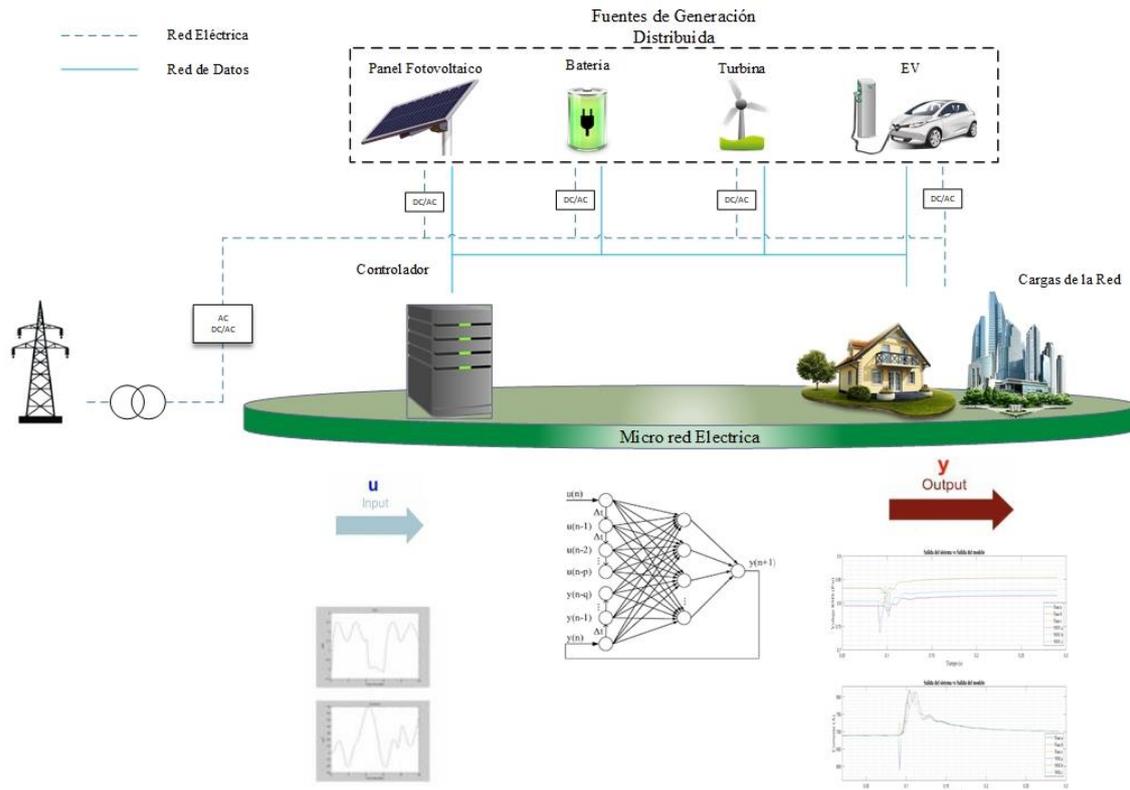


Figura 1. Modelo de la Micro - red AC/DC, asociada a una Red Neuronal.

en la siguiente Figura 2 se presenta una MR básica, donde se puede apreciar, una arquitectura sintetizada los las que consisten en zonas urbanas y rurales, como también para industria, se puede tener diferentes estructuras como anillo, paralelo o mallado y una gestión de comunicación de tipo jerárquico [2].

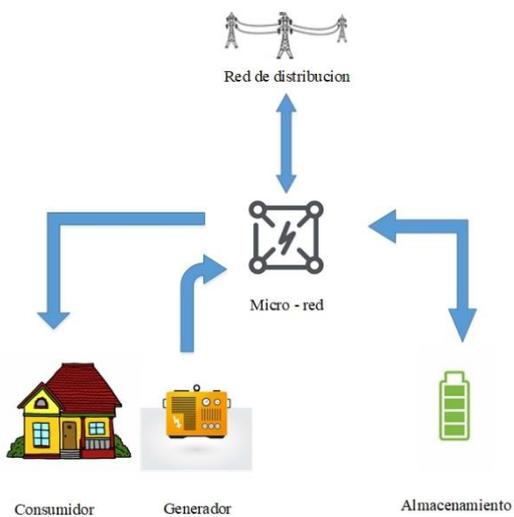


Figura 2. Estructura de la Micro – red básica.

Para tener una buena gestión de parte de la MR, se debe tener en cuenta un balance de la generación y demanda esto es indispensable, para el mejor funcionamiento de la MR la cual puede trabajar en modo aislado o en conexión a la red [19]–[21].

## 2.2 Fuentes de Generación Distribuida en las Micro - redes.

Las fuentes de Generación Distribuida, se han convertido en parte importante de las MR [22], [23] Los investigadores mencionan que, las fuentes de GD se pueden conocer como instalaciones de tamaño más reducido que los mismos centros de generación que existen hoy en día, por ello este sistema permite la conexión de cualquier punto a la red [1]. Esta MR tiene que dar la energía suficiente a un conjunto de cargas de manera eficiente. Para ello las fuentes de GD trabajan en el rango de baja potencia, ya que esto es beneficioso para las cargas

que se encuentran cerca de la MR, la cual proporciona una salida de DC a AC por medio de convertidores electrónicos y esto va dirigido a nuevos modelos para las MR [24]–[30].

En la figura 3 se puede apreciar un modelo básico de fuentes de GD, donde muchas veces el cliente deja de ser un consumidor, para convertirse en un productor – consumidor y así poniendo al cliente como parte de la red de eléctrica. Los sistemas de fuentes de GD usan diferentes tipos de generadores como: Paneles Fotovoltaicos, Aerogeneradores, Mini híbridos, motores etc.

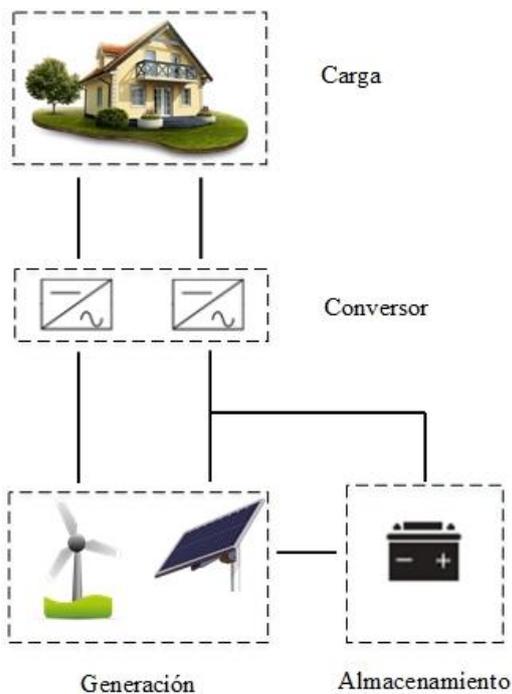


Figura 3. Modelo de generación distribuida.

Estos equipos se incorporan en los hogares de los nuevos clientes y se debe colocar convertidores electrónicos para el cambio de potencia, equipos de almacenamiento y equipos de medición [29], [31], [32].

A más de otorgar una eficiencia en el sistema de las MR, esto permite realizar otras operaciones [33] como:

- Reducir las pérdidas energéticas en los sistemas de distribución.

- Incrementar la calidad de servicio en cuanto a voltaje, corriente y armónicos de la red.
- Regenerar los niveles de voltaje para los clientes.
- Proyectar planes de expansión a lugares alejados de los sistemas de generación.

Los investigadores mencionan que estos sistemas están en auge de expansión y mejoramiento para brindar un mejor servicio con tecnología y energía renovable al consumidor de hoy en día. Esto demuestra que las fuentes de GD quieren lograr respuestas para las MR y mejorarlas utilizando fuentes de energía renovables [34].

### 3. Problema de Identificación de Sistemas No lineales.

Tener un modelo, es indispensable para iniciar algún análisis y en ocasiones para el control de un sistema, que en general la gran mayoría se basan en los parámetros conocidos del mismo. De igual forma se puede precisar un modelo, únicamente con un conocimiento previo y si es posible tener experiencias del modelo, a esto se lo conoce como Identificación de sistemas [4], [11], [12], [35].

A la Identificación de Sistemas con dinámicas de práctica no lineal de entradas y salidas se lo conoce como caja negra.

En los últimos años, los investigadores han desarrollado la identificación de sistemas con dinámicas no lineales, las mismas, deben estimar una similitud entre las entradas y salidas obtenidas por el algún sistema dinámico desconocido [15]. Esto ha desarrollado varios modelos, donde las redes neuronales artificiales, observadas como una estrategia de regresiones no lineales han visto que se puede desarrollar modelos. Sin embargo los modelos no lineales se adaptan mejor a los problemas complejos que se desarrollan hoy en día

[36]. Estos problemas se pueden presentar en una MR asociada a los sistemas de fuentes de GD ya que son considerados sistemas no lineales. Estos sistemas no lineales pueden figurar por la interconexión de modelos estáticos y estacionarios que se presentan en las fuentes de GD [4], [37]

### 3.1 Redes Neuronales Artificiales.

Las redes neuronales artificiales (RNA) imitan al sistema nervioso neuronal humano, con el propósito de tener un comportamiento inteligente para diferentes procesos. Los investigadores mencionan que las RNA, modelan procesos en paralelo para obtener modelos matemáticos las cuales son recreadas con mecanismos artificiales [38]. En la figura 4 se observa la estructura de una red neuronal artificial, donde se aprecian las capas de entrada, ocultas y salidas las mismas que son elegidas por el creador y se seleccionan mediante ensayo – error [39]. Las RNA han ganado importancia en los últimos años ya que a su desarrollo, pueden solucionar problemas complejos, los mismos que no pueden ser resueltos con métodos convencionales. Una ventaja que presenta las RNA, es que pueden aprender sobre un conjunto de comportamientos de un sistema y este

aprendizaje relaciona las entradas y salidas del mismo [40].

El entrenamiento de la RNA es el objetivo principal, ya que se desea encontrar que el conjunto de datos de entrada que sea mínimamente consistente o igual a los datos de salida para un entrenamiento idóneo. Las RNA se utilizan en ingeniería, y son modelos auto adaptables y no requieren tener ninguna estimación del problema de estudio, para que puedan encontrar modelos, los mismos son usados para dar soluciones a problemas complejos y que puedan aprender, memorizar, sintetizar y abastecer [41], [42] para las fuentes de GD.

### 3.2 Red Neuronal Autorregresiva no Lineal con entradas Exógenas (NARX).

La red neuronal NARX (Red neuronal Autoregresiva no lineal con entradas exógenas), es una generalización basada en el sistema ARX (modelo dinámico lineal de autorregresión con variables exógenas). El mismo es una herramienta para realizar la identificación de sistemas lineales y también para series de tiempo de caja negra [35], [43].

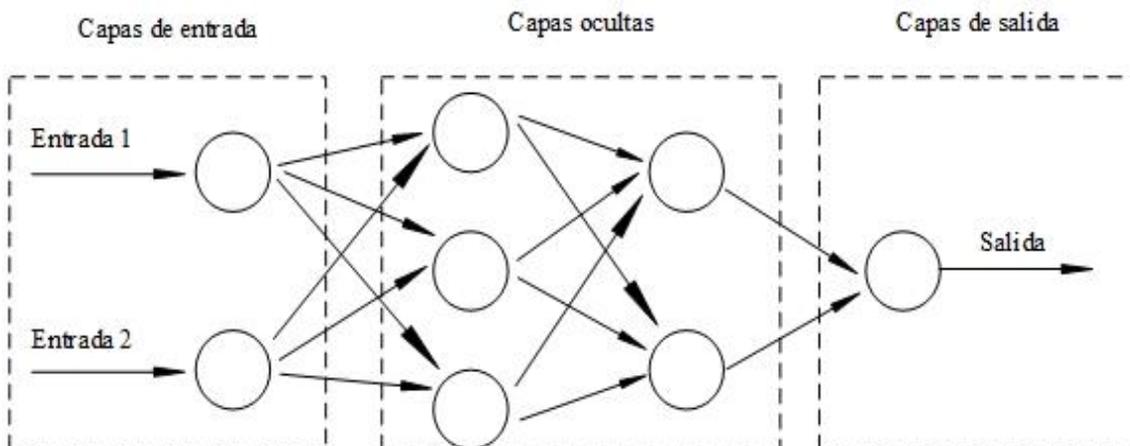


Figura 4. Red Neuronal Artificial.

La estructura base para la red neuronal se muestra en la figura 5 donde se ve las configuraciones de entrada y salida (unidireccionales).

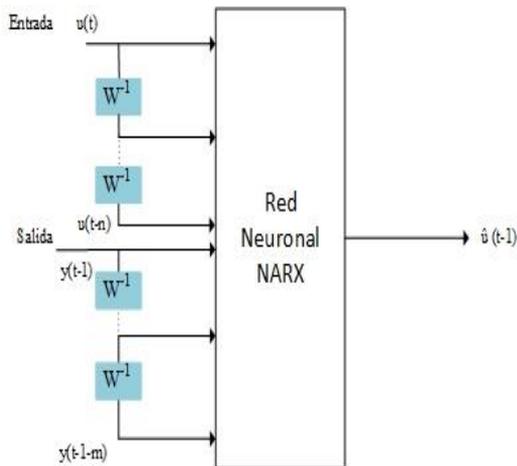


Figura 5. Modelo red neuronal NARX.

Los autores mencionan que los sistemas dinámicos no lineales pueden ser modelados mediante la red NARX, la cual se ha utilizado en varios estudios. Estos determinan o predicen valores futuros de series temporales a partir de los valores obtenidos, por lo que mencionan que es un modelo que se

adapta de la mejor manera a los sistemas dinámicos complejos [44], [45].

Para sacarle el mejor provecho, a la red neuronal NARX para las predicciones de series de tiempo, es necesario darle el mejor uso a la memoria de la red, con sus valores pasados de las series temporales, las mismas que son estimadas o encontradas, y son usadas en forma de retroalimentación para futuras respuestas [46].

En la figura 6 se observa la arquitectura utilizada para el ingreso de las entradas que serán en serie al principio y ya usadas, se realizará la identificación del sistema de caja negra y las partes exógenas de la red neuronal que se van a utilizar. Posterior a esto pasa a una arquitectura en paralelo para utilizar nuevas entradas al sistema de identificación. En la figura se observan bloques TD, los cuales representan las unidades de retardo de la señal de entrada como para la señal de salida y estos bloques le permiten a la red NARX, que analice las propiedades del sistema, para los procesos dinámicos a los que se sometió la red en el proceso de entrenamiento.

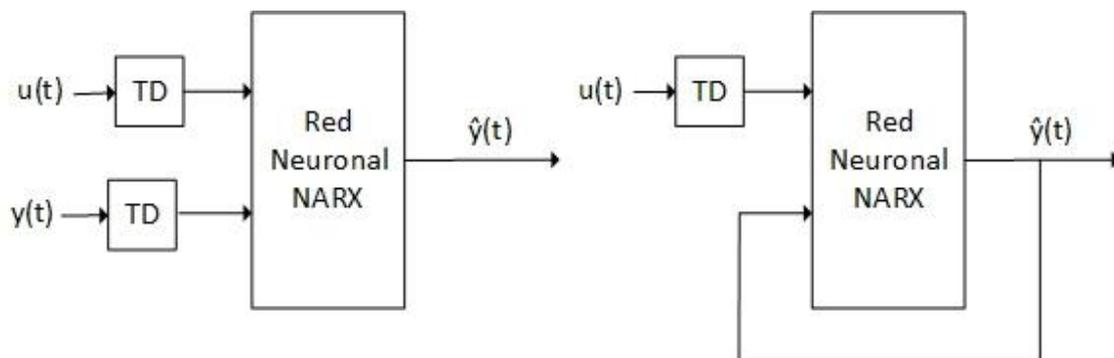


Figura 6. Arquitectura de entradas en Serie y Paralelo del modelo NARX.

El inicio del algoritmo NARX se lo estima mediante entradas y salidas del sistema a trabajar y vienen dados por:

$$W^N = \{[y(t), u(t); t = 1 \dots N]\} \quad (1)$$

Donde:

- $W^N$  Vector de entrada y salida.
- $y(t)$  Salidas del modelo en un instante  $t$ .
- $u(t)$  Entradas del modelo en un instante  $t$ .
- $t$  Instante de tiempo.

La estructura de la red neuronal NARX es la que se ve en la figura 6.

A esta estructura la ecuación que la representa es la siguiente [15]:

$$Y_t = f(Y_{t-1}, \dots, Y_{t-n_y}, U_{t-1}, \dots, U_{t-n_u}) + e_k \quad (2)$$

Donde:

$t$	Instante de tiempo.
$f$	Modelo no lineal deseado.
$Y_t$	Salidas del sistema en el instante $t$ .
$U_t$	Entrada del sistema en el instante $t$ .
$e_t$	Vector ruido en el instante $t$ .
$n_y, n_u$	Retrasos de la salida y entrada.

Para el entrenamiento correcto de la red NARX los investigadores han dicho que consiste en un proceso organizado utilizando la ecuación (1) para una buena organización. Durante el entrenamiento se necesita ingresar un número específico de entradas y salidas de la red. Mediante este proceso de entrenamiento se tiene varias ecuaciones a tener en cuenta a la hora de realizar correctamente el algoritmo NARX. Una de las ecuaciones es la implantación del modelo mediante la función que interpreta la salida a partir de las entradas del sistema original y también se tiene en cuenta el tiempo en que se guarda las estimaciones del sistema identificado. La ecuación es:

$$\hat{y}(t) = \hat{g}_N(t, u(t)) \quad (3)$$

Donde:

$\hat{g}_N$	Modelo de estimación identificado.
$\hat{y}(t)$	Salida del modelo en un instante $t$ .
$u(t)$	Entradas del modelo en un instante $t$ .
$t$	Instante de tiempo.

Se tiene que tomar en cuenta los parámetros o puntos de operación ( $\theta$ ) del sistema para una adecuada estimación del sistema a identificar por ello la ecuación siguiente define los parámetros de uso:

$$g = (t, \theta, u(t)) \quad (4)$$

Donde:

$u(t)$	Entradas del modelo en un instante $t$ .
$t$	Instante de tiempo.
$\theta$	Parámetros o puntos de operación.

Y para comprobar si el método usado es el correcto se tiene que chequear con una medición del error para visualizar un análisis correcto en la identificación del sistema de caja negra.

$$\varepsilon(t, \theta) = y(t) - g(t, \theta, u(t)) \quad (5)$$

Donde:

$\varepsilon$	Error.
$u(t)$	Entradas del modelo en un instante $t$ .
$y(t)$	Salidas del modelo en un instante $t$ .
$t$	Instante de tiempo.
$g(\theta)$	Parámetros o puntos de operación.

La red debe trabajar para identificar el sistema mediante caja negra, y se pueda obtener unos valores cercanos para que, la estimación sea la correcta al sistema original [45], [47], [48].

#### 4. Planteamiento del problema.

Considere, una fuente de GD acoplada a una MR AC/DC, la misma funciona conectada a la red o también en forma aislada. Esta MR está formada por un recurso de energía distribuida (DER) y un grupo de fuentes de energía inteligentes que están hechos para la transformación de energía a (DC/DC, DC/AC, AC/AC, bidireccional) también sistemas de protección, control y

monitoreo [11]. Este trabajo emplea la información observada de la MR híbrida MRH, estos datos son altamente no lineales para el estudio en proceso.

El rumbo fijado que se propone anteriormente, va a permitir obtener estimaciones semejantes a la información observada de la MR AC/DC. Los datos obtenidos de la fuente de GD se consideraran como variables de índice  $m$  ( $m$ ) y ángulo ( $ang$ ), los mismos serán usados para la estrategia de identificación y la obtención del modelo matemático para el sistema de MR. La identificación del sistema se lo hará basado en los datos observados:  $m(t)$ ,  $ang(t)$ ,  $v(t)$  y  $i(t)$  [2], [4], [11], [49].

#### 4.1 Modelo Matemático NARX.

La red neuronal NARX, será usada para estimar los datos observados en las fuentes de GD a las MR, esta estimación será lo acopladas más semejante posible a los datos originalmente. El algoritmo y variables se mostraran en las siguientes tablas. Este algoritmo será utilizado libremente y su modificación se la realizará con las necesidades de las fuentes de GD acoplada a la MR [4].

Para iniciar el algoritmo NARX lee los datos observados de la MR en la etapa de muestreo, posterior a esto el algoritmo procede al análisis y visualización del muestreo obtenido y al final el algoritmo realiza la identificación del modelo para su validación de resultados. Estos datos se los mostrara en las siguientes tablas. En la tabla 1 se observará las variables utilizadas en el para el algoritmo NARX que se muestra a continuación.

Tabla 1. Variables del Algoritmo

Símbolo	Variable	unidad
$u$	Datos observados de entrada del conversor	$m, ang$
$y$	Datos observados de salida del conversor	$V_{abc}, I_{abc}$
$t$	Tiempo	$s$
narx net	Red neuronal autorregresiva no lineal con entrada	na

	externa, con 10 neuronas.	
parametros	Prepara datos de entrada y series de tiempo objetivo. Para simulación.	
train	Entrena la red	
sim	Simulación de red abierta.	
gensim	Genera el bloque de simulink.	

En la tabla 2 se muestran las funciones del algoritmo NARX que han sido usadas para el correcto funcionamiento del sistema modelado.

Tabla 2. Funciones del Algoritmo.

Función	Descripción
d1, d2	Retrasos de la red
ysdata_V_NARX	Datos de voltaje de la red
ysdata_I_NARX	Datos de corriente de la red
narxnet	Red neuronal autorregresiva no lineal con entrada externa
preparets	Prepare datos de entrada y series de tiempo objetivo para simulación de red o capacitación
train	Entrenar red neuronal superficial
sim	Simula el modelo de la plata y la red neuronal entrenada.
gensim	Genera el bloque de Simulink para narx_net.

Tabla 3. Algoritmo NARX..

#### Algoritmo 1: Obtención dinámica del modelo.

Paso 1: **Entrada:**  $\{ u [m, ang]; y [V_{abc}, I_{abc}] \}$

Paso 2: **Salida:**  $\{ narx\_net; \}$

Paso 3: **Initialize:**  $u = u_i(data), y = y_i(data);$

$$Y_t = f(Y_{t-1}, \dots, Y_{t-n_y}, U_{t-1}, \dots, U_{t-n_u}) + e_k;$$

$$T = t(data); N_k = n_y, n_u, e_k;$$

$$d1 = [1:2]; d2 = [1:2];$$

$$narx\_net1 \leftarrow narxnet(d1, d2, 10);$$

Paso 4: **Entrenamiento:**

$$W^N = \{ [y(t), u(t)]; t = 1 \dots N \};$$

$$\hat{y}(t) = \hat{g}_N(t, u(t));$$

$$g(t, \theta, u(t)); \dots parametros$$

$$V_n(\theta) = \frac{1}{N} \sum_{t=1}^N |\varepsilon(t, \theta)|^2 \text{ error}$$

$$\theta(t) = \theta(t-1) + \mu_t R_t \gamma(t) \varepsilon(t) \text{ min error}$$

$$[p, Pi, Ai, i] \leftarrow preparets(narx\_net1, u, y);$$

$$narx\_net \leftarrow train(narx\_net1, p, t, Pi);$$

Paso 5: **Validación:** gensim(narx\_net, 0.002);

sim(modelo de validación);

Paso 6: **Retorna:** narx\_net; ysdata V NARX (t);  
ysdata I NARX (t)

## 5. Caso de Estudio.

Para el estudio correspondiente, se muestran los resultados de la identificación no lineal realizada al sistema de generación acoplado electrónicamente a una MR en AC/DC [2], [49], los datos obtenidos son resultados de simulaciones en el entorno Matlab/Simulink.

Para simular el modelo AC/DC, se va a utilizar varios elementos necesarios, a continuación se presentara varios equipos:

- 2 sistemas fotovoltaicos (PV).
- 2 Baterías para almacenamiento de energía (BEES).
- Un generador.
- Cargas lineales y no lineales.

El modelo AC/DC de la MR, va a tener 2 valores de distribución de voltaje, en el primario se tendrá 13.8 kV y en el secundario se tendrá 220 V. La Barra de DC está compuesta por 2 formaciones de PV y 2 baterías (BEES).

La formación del primer grupo de PV está compuesta por 42 módulos y estos tendrán una potencia nominal de 10.5 kW y la segunda formación está compuesta por 1750 módulos y estos tendrán una potencia nominal de 725 kW. Ambas formaciones de PV funcionaran con una irradiación solar de  $G = 1000 \text{ W/m}^2$  y a una temperatura de 25 °C [2], [49]. La frecuencia del sistema es de 60 Hz.

El BEES que trabaja en el lado de corriente continua (CC) será, una batería de litio de 120 VDC de voltaje nominal y el BEES que trabaja del lado de corriente alterna (CA) trabajara, con 3 baterías de níquel-metal-hidruro (Ni-MH) de 650 VDC de voltaje nominal, con una corriente nominal de 1.5 (Amp) y están enlazadas mediante una conexión en cascada y con un inversor lo cual permitirá que el voltaje varié de 650 VDC a 950 VAC.

Se utilizará un convertidor bidireccional boost-buck para que se conecte con el primer sistema de BEES, y se utilizara un convertidor Boost para que sea conectado a un enlace de formación de módulos PV los mismos están conectados a CC. Por el lado de corriente alterna se conectará 2 convertidores bidireccionales los mismos pueden ser usados como inversores o rectificadores [4].

Este sistema fue creado para que pueda trabajar con voltajes de 300 VDC y que entregue en la salida un voltaje de 150 VCA y viceversa, esto nos manifiesta que su gran rendimiento, la robustez que presenta este sistema y la flexibilidad. Va a generar una gran cantidad de niveles de voltaje para su desempeño en la AC/DC MR [2], [49].

Los tres casos de estudios mostrados en esta investigación están asociados al inversor bidireccional en la figura 8, se observa el modelo de estudio.

### 6.1 Datos obtenidos para todos los puntos de operación en la barra AC.

Para obtener los resultados de este trabajo, se necesita seleccionar los puntos de operación del modelo trabajar. Los datos seleccionados, serán todos los puntos de operación obtenidos en el BEES AC y el inversor, de la simulación como se muestra en la figura 7 de la AC/DC MR de los casos de estudio que se presenta.

Una vez que se obtengan los datos de MR AC/DC, se realizará una identificación del sistema dinámico con el uso del algoritmo NARX para que, la RN simule los datos originales y tengamos como resultado una exactitud al sistema original. Los puntos de operación se los presentará en las siguientes figuras. En las figuras se muestran los comportamientos de los resultados obtenidos de voltaje y corriente de la MR AC/DC propuesta.

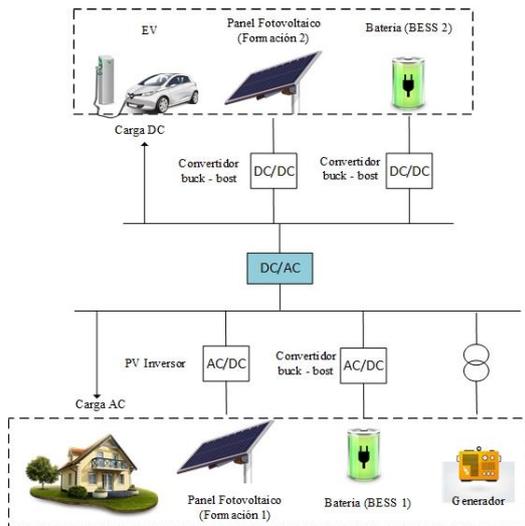


Figura 7. Esquema del caso de Estudio MR AC/DC.

### 5.1.1 Identificación y análisis de los puntos de operación del caso 1.

Para esta sección se va a trabajar con los datos del BEES de la simulación implementada a la MR AC/DC. Los datos a usar serán únicamente de voltaje y corriente y sus respectivas fases Va, Vb y Vc. Los valores a utilizar serán obtenidos de los dispositivos PV y el BEES, los mismos son vistos en la figura 7. Para este caso los valores de los puntos de operación serán todos los datos obtenidos del BEES. Por ende en los datos obtenidos se observará la dinámica de los elementos de la MR AC.

Los comportamientos dinámicos de las salidas de voltaje y corriente del conversor conectado a la MR. Para una mayor exactitud, eficiencia y mejor análisis de los puntos de operación de la MR, se tomaron todos los datos. .

En las figuras 8 y 9 se tiene las señales de prueba los cuales son los datos de voltaje (Va, Vb, Vc) y corriente (Ia, Ib, Ic) obtenidos del sistema dinámico del BEES y estos datos son serán usados para el entrenamiento de la RN y la identificación mediante el algoritmo NARX. Todos los puntos de operación serán tomados en cuenta, para el caso de

estudio y el posterior análisis del modelo.

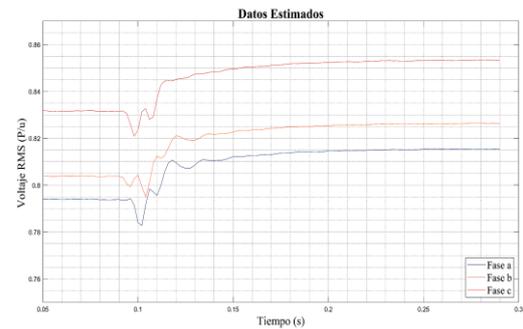


Figura 8. Datos de voltaje de la barra AC de la MR

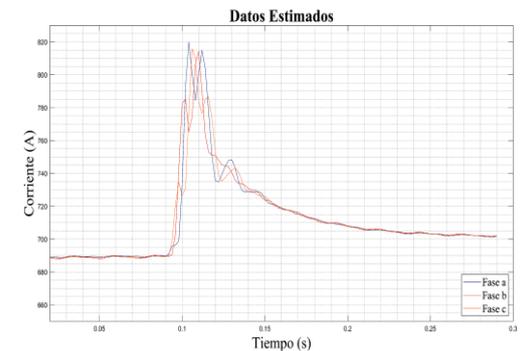


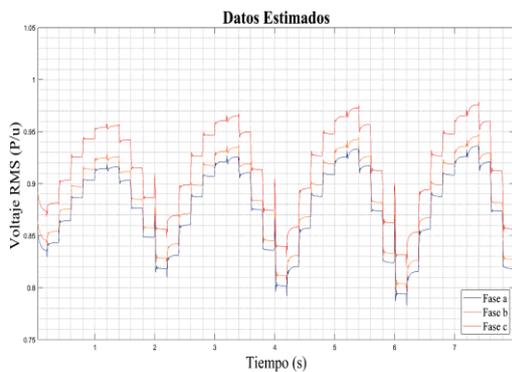
Figura 9. Datos de corriente de la barra AC de la MR

### 5.1.2 Identificación y análisis de los puntos de operación del caso 2.

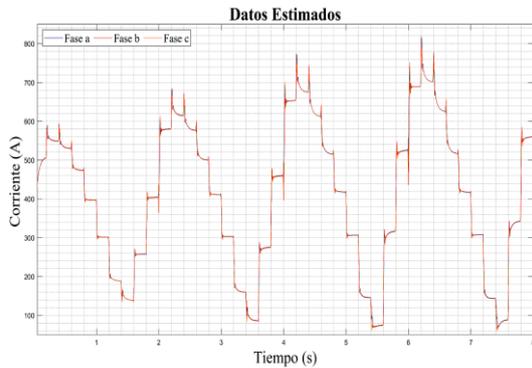
En esta parte se mostrarán los datos obtenidos del BEES en la parte de AC, de la simulación de la MR. Los datos adquiridos serán netamente de corriente y voltaje con las fases a, b y c. Los valores de entrada serán las señales de operación de los equipos PV, batería y el generador del modelo presentado en la figura 7. Para este estudio serán tomados en cuenta todos los puntos de operación correspondientes al inversor. En consecuencia el modelo utilizado verá la dinámica del BEES entre el lado de CC de la MR y el lado de CA.

A continuación, en las siguientes figuras 10 y 11. Se apreciará la corriente (Ia, Ib e Ic) y voltaje (Va, Vb, Vc) del modelo dinámico y esto conlleva a un sistema MIMO por ende se obtendrá varias entradas y varias salidas. Por ende las variables del modelo de la figura 8 serán

tomadas en cuenta, todos los puntos de operación del modelo y posterior a esto para la identificación del sistema mediante la RN del algoritmo NARX. También se tiene los resultados de las señales de prueba de la corriente ( $I_a$ ,  $I_b$ ,  $I_c$ ) y voltaje ( $V_a$ ,  $V_b$ ,  $V_c$ ) obtenidos del sistema dinámico del inversor propuesto anteriormente y estos resultados obtenidos serán usados para la identificación mediante el algoritmo NARX. Todos los puntos de operación serán tomados en cuenta, para el caso de estudio y el posterior análisis del modelo. Los datos de entrada serán  $m$  y  $ang$ , para cada caso de estudio.



**Figura 10.** Resultados observados de la corriente en la barra AC de la MR



**Figura 11.** Resultados observados del voltaje en la barra AC de la MR

## 6. Análisis de resultados y validación del modelo .

Ahora con los puntos de operación de la MR AC/DC ya en marcha, se puede realizar la identificación del sistema en el BESS. Se obtendrá los resultados usando la RN mediante algoritmo NARX, la

cual realizará la comparación y el posterior ajuste de la señal original, con la señal que será estimada con el algoritmo NARX.

Una vez que los puntos de operación han sido establecidos, es sumamente necesario ver si el modelo que se obtiene con la simulación del algoritmo NARX describe, con una precisión el comportamiento dinámico del sistema BEES. Es decir, si los datos de salida del modelo de la MR AC/DC, se ajustan a los datos obtenidos de la simulación del modelo con los datos originales. Posterior a este análisis se determinará una validación del modelo. El método utilizará los puntos de operación obtenidos del modelo original del sistema BEES, para la identificación de caja negra, con el cual se obtendrá un sistema MIMO con dos entradas ( $m$  y  $ang$ ) y las salidas como el voltaje ( $V_a$ ,  $V_b$ ,  $V_c$ ) y la corriente ( $I_a$ ,  $I_b$ ,  $I_c$ ) del modelo la MR AC/DC del sistema BEES.

### 6.1 Análisis del Modelo NARX en el caso 1.

Para realizar la validación de los resultados, se tiene que ver como fue el entrenamiento de la RN para que la simulación no falle y sea lo más exacta posible al modelo original de la MR del sistema BEES.

La RN fue entrenada mediante el software Matlab con el código de programación desarrollado para este estudio y se tiene lo siguiente.

El número de capas y neuronas, para el entrenamiento de la RN del caso 1, son determinadas empíricamente por la programación del algoritmo, ya que para el dimensionamiento de la topología de este tipo de redes existe la ecuación (1), la misma, que define las capas y neuronas necesarias para un entrenamiento eficaz de la RN. De igual forma estas pruebas son realizadas con una validación de prueba y error, lo cual

hace el algoritmo desarrollado en Matlab.

En la figura 12 se presenta la RN entrenada mediante el algoritmo NARX, la misma que dio las mejores estimaciones para el modelo original.

Esta RN es una red recurrente, (retroalimentación de la entrada con la salida de la red), tiene 2 retardos para las señales de entrada y salida, tiene 10 neuronas en la capa oculta y 3 neuronas en la en la capa de salida.

Este diseño de la RN es la más adecuada para el análisis y la validación de los puntos de operación de la MR, ya que simula la dinámica del sistema correctamente.

La comprobación se la realiza con el modelo obtenido, los cuales son los datos reales del sistema BEES de la MR de las figuras 9 y 10 y estos datos son los voltajes y corrientes. Con estos datos, se obtendrá un sistema MIMO, el cual se obtendrá mediante la identificación del sistema de la RN mediante el algoritmo NARX. El resultado del estudio se lo presenta en las figuras 13 y 14.

### 6.1.1 Análisis y Validación de los puntos de operación de la MR AC del caso 1.

El método desarrollado realiza la identificación del sistema y esto se lo hará mediante los puntos de operación obtenidos de la MR, para comprobar la validez del sistema. Este análisis obtendrá un sistema MIMO con 2 entradas ( $m$ ,  $ang$ ) y 2 salidas compuestas por un voltaje ( $Va$ ,  $Vb$ ,  $Vc$ ) y corriente ( $Ia$ ,  $Ib$ ,  $Ic$ ) y estos datos tendrán una exactitud al sistema dinámico BEES.

En la figura 13 se puede apreciar el alto grado de similitud entre los puntos de operación de voltaje del sistema del BEES de la MR, con la identificación del sistema de caja negra, realizado mediante la RN del algoritmo NARX. Y en la figura 14 se aprecia el grado de exactitud, entre los puntos de operación de la corriente simulado y validado del sistema BEES, con la identificación del sistema de caja negra implementada con la RN del algoritmo NARX. También representa la habilidad que tiene la Red neuronal NARX, para estimar o predecir los resultados correctos para los que está siendo utilizada.

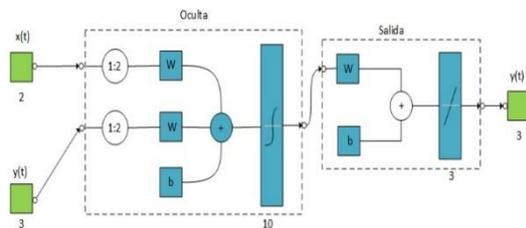
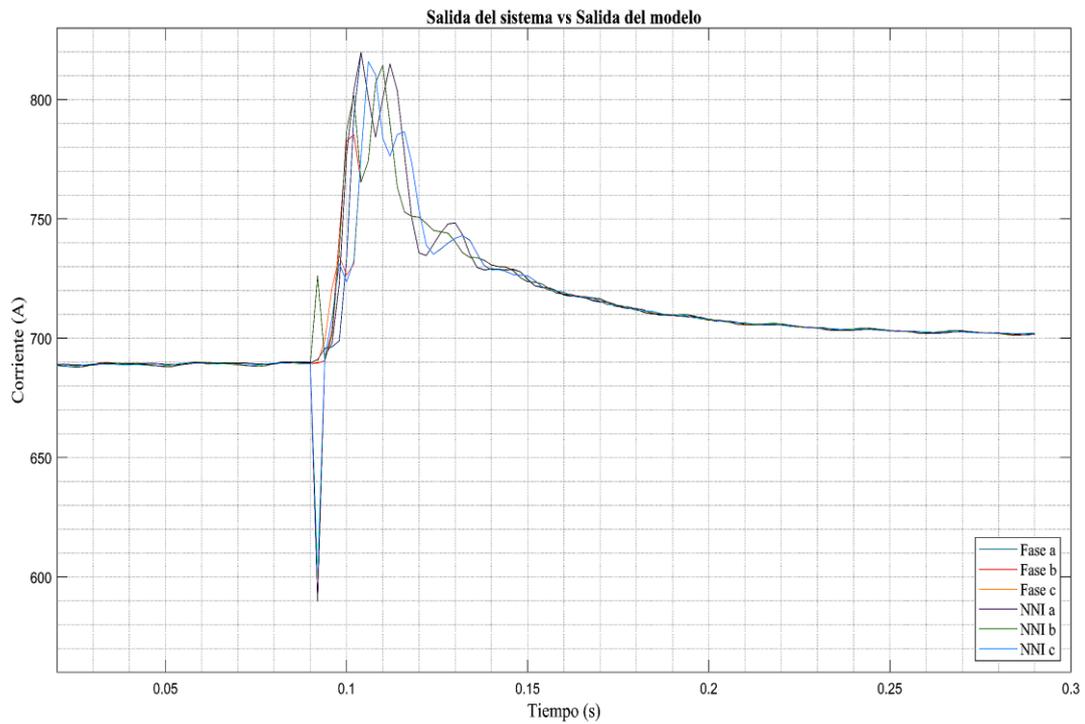
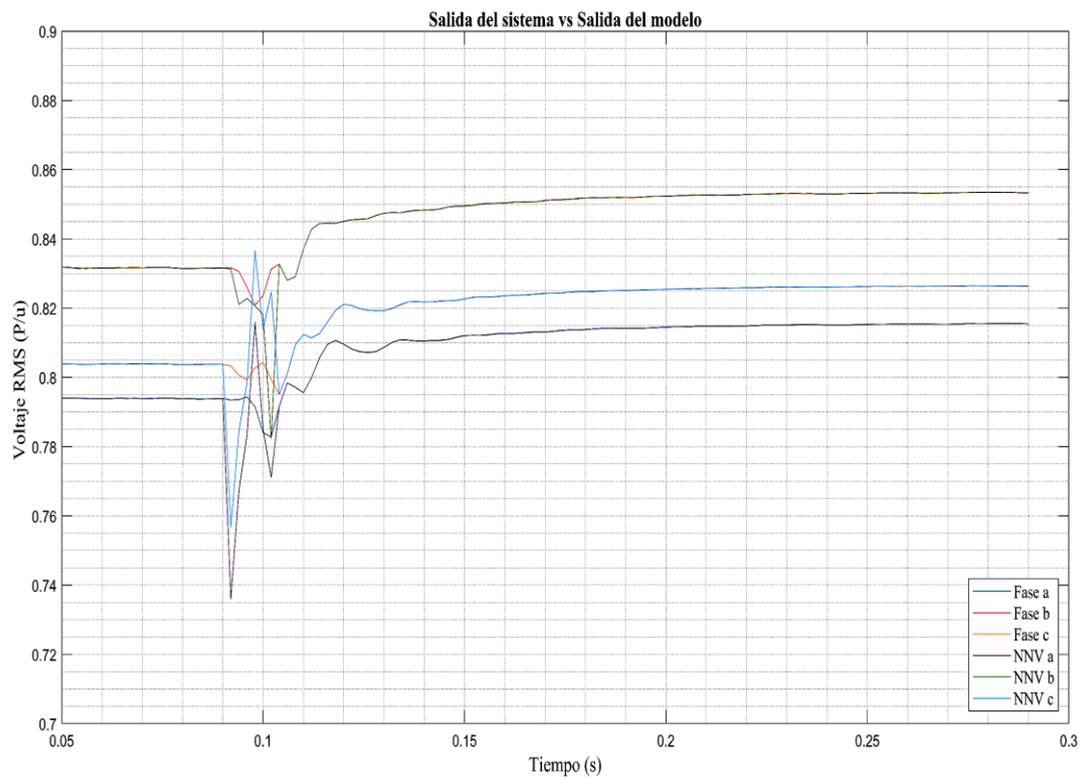


Figura 12. Estructura de la red neuronal caso 1.



**Figura 13.** Corriente del modelo y puntos de operación, en la fase de validación.



**Figura 14.** Voltaje del modelo y puntos de operación, en la fase de validación.

El aprender datos de salida que no han sido presentados, es una ventaja a la hora de adquirir conceptos nuevos. De esta manera la RN puede tratar con

información que nunca antes se le había presentado y ahora da como resultado una exactitud del sistema de la MR AC en este caso de estudio. En este caso el

modelo NARX predice de manera exacta la salida exógena de voltaje y corriente del sistema BEES de la MR AC/DC, lo cual nos dice que el sistema de identificación de caja negra estima de manera perfecta los puntos de operación de la MR en funcionamiento y la inteligencia artificial desarrollada, está siendo efectiva en este caso de estudio. El error presentado por el entrenamiento del algoritmo es el correcto, además se puede observar el valor promedio de los errores por fase de la identificación para las salidas de V (0.0008 pu, 0.0013 pu, 0.0006 pu) y I (-0.1582 A, -0.9720 A, -0.0794 A). El error de entrenamiento es calculado mediante la diferencia de los datos idóneos del sistema dinámico real y los datos adecuados del sistema no lineal NARX obtenido. Al examinar la dinámica de los valores obtenidos se observa que el funcionamiento del algoritmo NARX es aceptable. Los errores de estimación del modelo propuesto para la salida de V y I se pueden observar en las figuras 15 y 16.

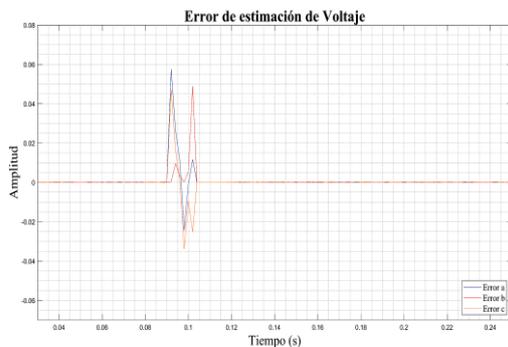


Figura 15. Error de identificación de voltaje.

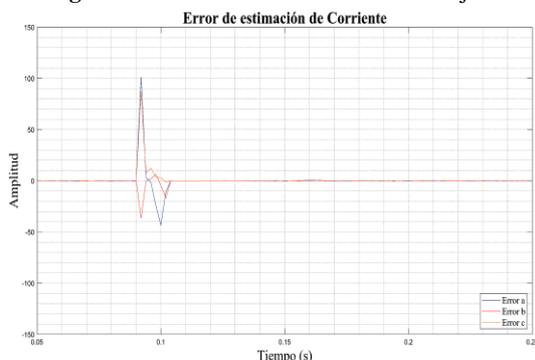


Figura 16. Error de identificación de corriente.

## 7.2 Validación de resultados del modelo NARX en el caso 2.

La validación de los resultados se observa mediante la RN entrenada, la cual debe ser lo más exacta posible, a la salida de datos del modelo original de la MR del sistema BEES. El entrenamiento de la RN fue realizado con el algoritmo desarrollado NARX mediante el software Matlab, el cual, debe dar como resultado un modelo de identificación de sistema similar, al modelo original.

Para el caso 2 el número de capas y neuronas son determinadas de forma empírica, las mismas son proporcionadas por el desarrollo del código de programación, y también con el desglose de la ecuación (1) la cual define las capas y neuronas necesarias para un mejor desarrollo del sistema de identificación de caja negra.

En la figura 17 se presenta RN del algoritmo NARX ya entrenada, y esta red es el mejor resultado para la comprobación del sistema original con el sistema identificado. Para la RN el algoritmo NARX, implementó 2 retardos en la entrada y salida del sistema, está constituido por 10 neuronas en la capa oculta y 3 neuronas en la capa de salida. Esta estructura es la más adecuada para el desarrollo de la identificación del sistema a trabajar y fue encontrada por el algoritmo desarrollado en Matlab y las ecuaciones indicadas anteriormente.

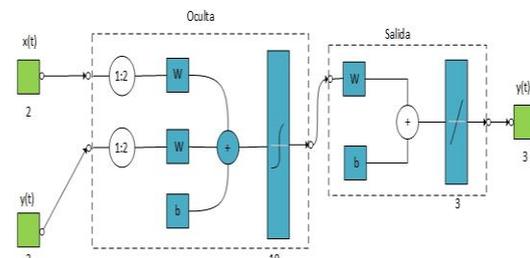


Figura 17. Estructura de la red neuronal caso 2.

La validación del modelo identificado se lo realiza mediante la comprobación del sistema original de las figuras 10 y 11 con el sistema identificado por el algoritmo NARX.

El resultado del estudio realizado se lo presenta en las figuras 18 y 19.

### 7.2.1 Análisis e Identificación de los puntos de operación de la MR AC caso 2.

El modelo implementado obtiene la identificación del sistema mediante los puntos de operación del sistema de la MR. Esto llevará a la comprobación y dar una validez al sistema a obtener. Se obtendrá un sistema MIMO con 2 entradas ( $m$ ,  $ang$ ) y dos respuestas las cuales serán en voltaje ( $Va$ ,  $Vb$ ,  $Vc$ ) y corriente ( $Ia$ ,  $Ib$ ,  $Ic$ ) y estas respuestas deberán tener una exactitud al sistema dinámico de entrada (BEES).

En la figura 16 se observa la gran similitud entre los puntos de operación obtenidos de la simulación de la MR del

sistema BEES, con la identificación del sistema realizado con el sistema de caja negra implementado mediante el algoritmo NARX. Y en la figura 17 se mira la gran similitud entre los puntos de operación de la corriente simulada y validada del sistema BEES, con la identificación del sistema implementada con la RN del algoritmo NARX.

Las figuras 18 y 19 representan la gran capacidad que tiene la Red neuronal NARX a la hora de aprender y estimar nuevos resultados para los que se quieren obtener. Esta red maneja datos empíricos, que solo a la hora de entrenarla nos da como resultado la identificación del sistema de caja negra, para la posterior comparación de los puntos de operación originales de la MR AC del sistema BEES, con los datos del nuevo sistema de identificación a obtener.

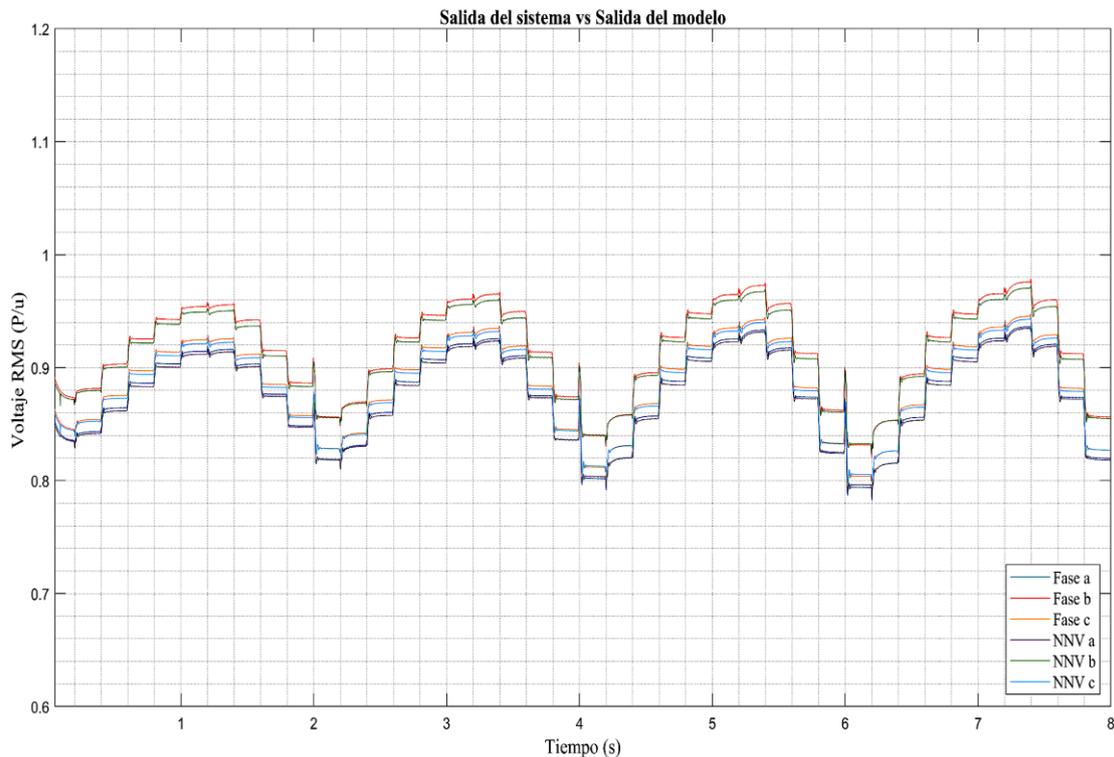
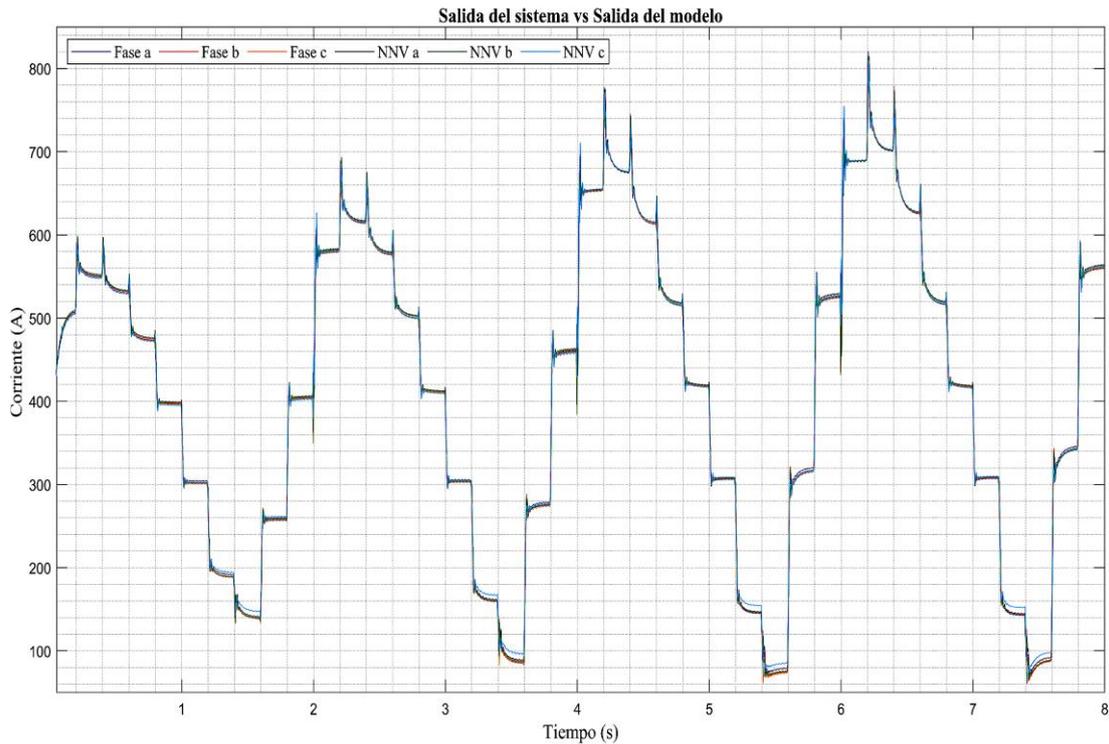


Figura 18. Voltaje del modelo y validación del sistema de identificación.

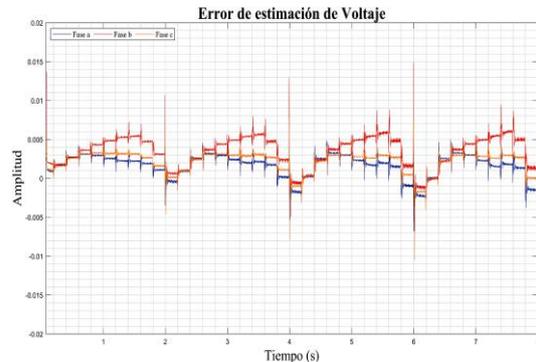


**Figura 19.** Corriente del modelo y validación del sistema de identificación.

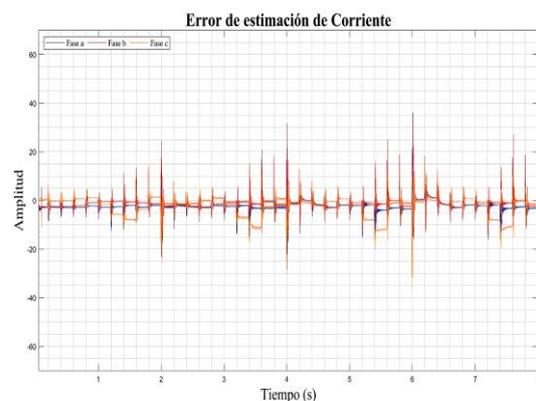
Para este caso de estudio, el modelo propuesto, cumple con las estimaciones precisas, las cuales son comparadas con los puntos de operación de voltaje y corriente del modelo original obtenido del sistema BEES de la MR AC/DC, de manera que el sistema de identificación funciona para este caso en especial, ya que predice los valores originales sin ningún problema.

El error presentado por la estimación del algoritmo es adecuado, además se puede apreciar el valor promedio de los errores por fase de la identificación para las salidas de V (0.0015 pu, 0.0035 pu, 0.0022 pu) y I (-2.4344 A, -1.3484 A, -2.4942 A). El error de estimación es calculado mediante la diferencia de los datos correspondientes del sistema dinámico real y los datos correspondientes del sistema no lineal NARX obtenido. Al analizar la dinámica de los valores resultantes se observa que el funcionamiento del algoritmo NARX es aceptable. Los errores de estimación del modelo propuesto para la salida de V

y I se pueden observar en las figuras 20 y 21.



**Figura 20.** Identificación de errores de Voltaje.



**Figura 21.** Identificación de errores de Corriente.

## 7. Conclusiones.

En esta investigación se ha proporcionado un modelo NARX, para predecir salidas exógenas de voltaje y corriente en las fuentes de generación distribuidas asociadas a las AC/DC MRs eléctricas híbridas. De tal modo que se ha comprobado que el uso de inteligencia artificial basada en las Redes neuronales y los métodos estadísticos son eficientes en el campo de la identificación de sistemas y se determinó que es una herramienta poderosa para modelar procesos dinámicos eléctricos de un grado de complejidad alto.

Se ha puesto en marcha la simulación de las MRs AC/DC y se ha considerado todos los puntos de operación del sistema BEES, para los casos presentados. Los resultados obtenidos han sido los esperados, con el uso del modelo NARX el cual, tomó los datos del sistema original para el estudio y su posterior entrenamiento para obtener los datos de identificación resultante.

La ventaja de utilizar el algoritmo NARX es que permite predecir una serie de datos estadísticos o estocásticos. Esto ayuda a que el algoritmo haga una evaluación de los datos y entrene una RN en función de los datos originales, de una manera fácil y automatizada. Una novedad existente es que, al usar este algoritmo NARX, este funciona como caja negra y este mecanismo relaciona las entrada con la salida del sistema original, por lo contrario al usuario se le complica apreciar lo que sucede dentro de la red para saber cómo funciona o a su vez, el saber cómo interactúa el algoritmo para que pueda solucionar la tarea de estimar los datos originales con los datos identificados. Un problema del algoritmo NARX, es cuando se tiene los datos entrenados o estimados, no se puede realizar modificaciones externas para que exista una exactitud al sistema original.

Por último, el algoritmo utilizado basado en NARX es capaz de entrenar una red que reproduce de forma adecuada la mayoría de los puntos operación de la MRH en AC y DC. Por las razones antes expuestas se considera que el método propuesto puede ser usado para la obtención de modelos no lineales de MRs.

## 8. Trabajos Futuros.

Para trabajos futuros se propone la detección e identificación de fallas, sobre la corriente de secuencia positiva y negativa para los sistemas de energía eléctrica.

Adicionalmente, los resultados del presente estudio servirán de base fundamental para otros algoritmos de detección e identificación de fallas internas o externas asociadas a los sistemas de control de las MRs.

Se propone trabajar en futuros estudios que enmarquen estrategias de control no lineal y tolerancia a fallas de convertidores electrónicos de potencia en las MRs.

Finalmente, se puede realizar estudios para estrategias de control tolerante a fallas, que mejoren confiabilidad de las MRs y los sistemas que lo componen.

## 9. Referencias.

- [1] M. S. Mahmoud, S. Azher Hussain, and M. A. Abido, "Modeling and control of microgrid: An overview," *J. Franklin Inst.*, vol. 351, no. 5, pp. 2822–2859, May 2014.
- [2] L. Ortiz, R. Orizondo, A. Aguila, J. W. Gonz, I. Isaac, and J. L. Gabriel, "Hybrid AC / DC microgrid test system simulation : grid-connected mode," *Heliyon*, vol. 5, no. August, p. 21, 2019.
- [3] H. Bevrani, B. Francois, and T. Ise, *Microgrid dynamics and control*. 2017.

- [4] L. Ortiz, L. B. Gutiérrez, J. W. González, and A. Águila, “A novel strategy for dynamic identification in AC/DC microgrids based on ARX and Petri Nets,” *Heliyon*, vol. 6, no. March, p. 18, 2020.
- [5] J. Hare, X. Shi, S. Gupta, and A. Bazzi, “Fault diagnostics in smart micro-grids: A survey,” *Renew. Sustain. Energy Rev.*, vol. 60, pp. 1114–1124, 2016.
- [6] B. Kroposki *et al.*, “Autonomous Energy Grids Preprint Autonomous Energy Grids,” vol. 18302, no. October 2017, 1975.
- [7] F. M. Armas Chamorro and L. Ortiz Matos, “Modelización con Petri Net de una aplicación automática de diagnóstico y restauración de avería en sistema de distribución,” Universidad Politécnica Salesiana, 2015.
- [8] J. L. M. Bastidas and L. O. Matos, “Localización de fallas en microredes eléctricas basado en un modelo Markoviano.,” Universidad Politécnica Salesiana, 2018.
- [9] L. Ortiz Matos, A. Aguila Tellez, R. C. Hincapié Reyes, and J. . González Sanchez, “Multi-Criteria Optimization of the Deployment of a Grid for Rural Electrification Based on a Heuristic Method,” *IOP Conf. Ser. Earth Environ. Sci.*, vol. 73, no. 1, p. 012020, 2017.
- [10] N. Hatzargyriou editor of compilation, *Microgrid : architectures and control*. 2014.
- [11] L. Ortiz M., L. Benigno G., J. W. González S., and A. Aguila T., “An ARX-Petri Nets algorithm for Active Identification of an AC / DC Microgrid Simulation,” in *2019 IEEE 4th Colombian Conference on Automatic Control (CCAC)*, 2019, p. 6.
- [12] P. Arafet, F. Chang, M. Torres, and H. Dominguez, “Métodos de Identificación dinámica,” no. May, p. 112, 2015.
- [13] A. U. Krismanto and N. Mithulanathan, “Identification of modal interaction and small signal stability in autonomous microgrid operation,” *IET Gener. Transm. Distrib.*, vol. 12, no. 1, pp. 247–257, 2018.
- [14] S. Garrido, “Identificación , Estimación y Control de Sistemas No-lineales mediante RGO,” *Control*, no. February 2000, p. 187, 1999.
- [15] Y. Liu, H. Wang, J. Yu, and P. Li, “Selective recursive kernel learning for online identification of nonlinear systems with NARX form,” *J. Process Control*, vol. 20, no. 2, pp. 181–194, 2010.
- [16] F. Martin-Martínez, A. Sánchez-Miralles, and M. Rivier, “A literature review of Microgrids: A functional layer based classification,” *Renew. Sustain. Energy Rev.*, vol. 62, pp. 1133–1153, 2016.
- [17] E. Planas, J. Andreu, J. I. Gárate, I. Martínez De Alegría, and E. Ibarra, “AC and DC technology in microgrids: A review,” *Renew. Sustain. Energy Rev.*, vol. 43, pp. 726–749, 2015.
- [18] SERGIO ANDRÉS GALLARDO REBOLLEDO, “Redirección Y Optimización Del Consumo Eléctrico De Una Micro-Red Haciendo Uso Del Protocolo Data Distribution System.,” 2020.
- [19] B. Lascano and E. Paul, “Diseño De Micro-Redes Eléctricas Utilizando Energía Fotovoltaica Para El Sistema Auxiliar De Emergencia Energética En Edificaciones De Actividades Comerciales,” 2020.
- [20] D. Carrión and L. Ortiz, “Generación distribuida a partir de bicicletas estáticas y sistemas

- híbridos,” *Ingenius*, vol. 10, pp. 44–48, 2013.
- [21] A. Sallam and O. Malik, “Microgrids and Smart Grids,” *Electr. Distrib. Syst. Second Ed.*, pp. 553–580, 2018.
- [22] D. S. Kumar and J. S. Savier, “Impact analysis of distributed generation integration on distribution network considering smart grid scenario,” *TENSYMP 2017 - IEEE Int. Symp. Technol. Smart Cities*, pp. 3–7, 2017.
- [23] S. I. Freire Piedra and L. Ortiz Matos, “Modelado y simulación de un sistema automático de adquisición de datos en centrales hidroeléctricas pequeñas,” Universidad Politécnica Salesiana, 2015.
- [24] A. Téllez, A. Robayo, G. López, L. Ortiz, I. Isaac, and J. González, “Optimal sizing of distribution transformers using exhaustive search algorithm,” in *2019 FISE-IEEE/CIGRE Conference - Living the energy Transition (FISE/CIGRE)*, 2019.
- [25] A. Aguila Téllez, G. M. Gutiérrez Serna, D. L. González Samueza, and M. L. Ortiz, “Optimum location and sizing of capacitor banks using VOLT VAR compensation in micro-grids,” *IEE Lat. Am. Trans.*, vol. 18, no. 3, pp. 465–472, 2020.
- [26] G. K. Chinchuña Toledo and L. Ortiz Matos, “Mejoramiento de la fiabilidad en microrredes mediante el control robusto de voltaje usando técnicas pasivas de tolerancia a fallos,” Universidad Politécnica Salesiana, 2018.
- [27] J. G. B. Sánchez and L. O. Matos, “Estrategia de tolerancia a fallas por condiciones ambientales para IEDS en subestaciones de distribución,” Universidad Politécnica Salesiana, 2016.
- [28] L. O. Matos, J. Wilson, and G. Sanchez, “Reconfiguration Strategy for Fault Tolerance of Power Distribution Systems Using Petri Net,” in *Ecuador Technical Chapters Meeting (ETCM), IEEE*, 2016.
- [29] D. Arias Cazco, R. A. Robayo Vasco, and L. Ortiz Matos, “Novel inteligente Step Voltaje Regulator (SVR) for residential electrical connections,” *IEEE Lat. Am. Trans.*, vol. 14, no. 4, pp. 1656–1661, 2016.
- [30] A. Aguila, D. Carrión, and L. Ortiz, “Analysis of power losses in the asymmetric construction of electric distribution systems,” *IEE Lat. Am. Trans.*, vol. 13, no. 7, pp. 2190–2194, 2015.
- [31] J. Domínguez, *Energías renovables y generación distribuida.*, no. September. 2018.
- [32] O. D. Montoya Giraldo, A. Grajales, L. F. Grisales, and C. A. Castro, “Ubicación y operación eficiente de almacenadores de energía en micro-redes en presencia de generación distribuida,” *Rev. CINTEX*, vol. 22, no. 1, pp. 97–117, 2017.
- [33] D. Blacio and J. Palacios, “TESIS DESARROLLO DE UN ALGORITMO DE INTERRELACIÓN PARA MICROREDES DE DISTRIBUCIÓN ELÉCTRICA,” *Artic. Ecuador*, vol. 1, no. 5, pp. 1–127, 2015.
- [34] L. F. Grisales, B. J. Restrepo Cuestas, and F. E. Jaramillo\*\*\*, “Ubicación y dimensionamiento de generación distribuida: una revisión TT - Location and sizing of distributed generation: a review,” *Cienc. e Ing. Neogranadina*, vol. 27, no. 2, pp. 157–176, 2017.
- [35] H. K. Sahoo, P. K. Dash, and N. P. Rath, “NARX model based nonlinear dynamic system

- identification using low complexity neural networks and robust  $H_{\infty}$  filter,” *Appl. Soft Comput. J.*, vol. 13, no. 7, pp. 3324–3334, 2013.
- [36] F. Jurado and J. Carpio, “Modelado de la micro-turbina en el sistema de distribución mediante estructuras NARX,” *IEEE Lat. Am. Trans.*, vol. 1, no. 1, pp. 34–39, 2003.
- [37] M. Milanese and C. Novara, “Set Membership identification of nonlinear systems,” *Automatica*, vol. 40, no. 6, pp. 957–975, 2004.
- [38] C. Catalán and N. Alejandro, “Predicción de potencia a corto plazo para plantas fotovoltaicas utilizando redes neuronales artificiales,” 2017.
- [39] C. Iván and C. Rodríguez, “MODELADO Y SIMULACIÓN MICRORRED,” 2017.
- [40] P. Pesántez, “Planificación eficiente de redes inteligentes (smart grids) incluyendo la gestión activa de la demanda: aplicación a Ecuador,” p. 313, 2018.
- [41] U. De and N. Y. De, “Incorporation of Artificial Intelligence in a virtual basic twin of an industrial robot,” 2019.
- [42] J. P. Fossati, “Diseño de redes neuronales inteligentes para la realización de pronósticos en microrredes eléctricas,” *Memoria. Investig. en Ing.*, vol. 17, no. 17, pp. 1–13, 2019.
- [43] A. Rahmani and A. Deihimi, “Reduction of harmonic monitors and estimation of voltage harmonics in distribution networks using wavelet analysis and NARX,” *Electr. Power Syst. Res.*, vol. 178, no. April 2019, p. 106046, 2020.
- [44] M. Moumouni Hamidou, N. Talibi Soumaïla, B. Seibou, A. Akim Salami, A. Kosso Moustapha, and M. Saïdou, “Electrical Charge of Niamey City Modelisation by Neural Network,” *Sci. J. Energy Eng.*, vol. 7, no. 1, p. 13, 2019.
- [45] Z. Boussaada, O. Curea, A. Remaci, H. Camblong, and N. M. Bellaaj, “A nonlinear autoregressive exogenous (NARX) neural network model for the prediction of the daily direct solar radiation,” *Energies*, vol. 11, no. 3, 2018.
- [46] L. Ruiz, M. Cuéllar, M. Calvo-Flores, and M. Jiménez, “An Application of Non-Linear Autoregressive Neural Networks to Predict Energy Consumption in Public Buildings,” *Energies*, vol. 9, no. 9, p. 684, 2016.
- [47] B. Morcego Seix, “Estudio de redes neuronales modulares para el modelado de sistemas dinámicos no lineales.,” *Tesis*, pp. 19–55, 2000.
- [48] G. C. Luh and C. Y. Wu, “Inversion control of non-linear systems with an inverse NARX model identified using genetic algorithms,” *Proc. Inst. Mech. Eng. Part I J. Syst. Control Eng.*, vol. 214, no. 4, pp. 259–271, 2000.
- [49] L. Ortiz, R. Orizondo, A. Águila, J. W. González, G. J. López, and I. A. & Isaac, “Hybrid AC/DC microgrid (HMG) test system simulation (<https://www.mathworks.com/matlabcentral/fileexchange/73878-hybrid-ac-dc-microgrid-hmg-test-system-simulation>).” MATLAB Central File Exchange, 2020.

## 10. Estado del Arte.

### 10.1 Matriz de Estado del Arte

MODELO Y ANALISIS DE ESTABILIDAD PARA EL CONTROL JERARQUICO DE MICRO-REDES ELECTRICAS AC USANDO MULTIPLES CRITERIOS																										
	DATOS			TEMÁTICA					FORMULACION DEL PROBLEMA				RESTRICCIONES DEL PROBLEMA				PROPUESTAS PARA RESOLVER EL PROBLEMA				SOLUCIÓN PROPUESTA					
	AÑO	TÍTULO DEL ARTÍCULO	CITAS	Micro - redes	Generación Distribuida	Identificación de Sistema No lineales	Sistema Dinamico	Redes Neuronales	Modelo NARX	Estimacion de sistemas Dinamicos	Capacidad de entranamiento de la red neuronal	Micro - redes	Algoritmo desarrollado NARX	Prediccion de puntos de operación	Condiciones normales del sistema operante	Operación del sistema sin fallos	Reduccion de perdidas energeticas	Modo aislado de la red autonoma	Redes Neuronales	Modelo NARX	Sistemas de Identificacion	Estructura Caja Negra	Mejoramiento de las Micro - redes electricas	Modelo optimo NARX	Implementacion Sistemas de identificacion	Generacion Distribuida
1	2014	Modeling and control of microgrid: An overview	196	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>					<input checked="" type="checkbox"/>			<input checked="" type="checkbox"/>			<input checked="" type="checkbox"/>				<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>			<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
2	2017	Hybrid AC/DC microgrid test system simulation: grid-connected mode	123	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>								<input checked="" type="checkbox"/>			<input checked="" type="checkbox"/>						<input checked="" type="checkbox"/>				<input checked="" type="checkbox"/>
3	2016	Fault diagnostics in smart micro-grids: A survey	75									<input checked="" type="checkbox"/>			<input checked="" type="checkbox"/>					<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>			<input checked="" type="checkbox"/>	
4	2017	Autonomous Energy Grids Preprint Autonomous Energy Grids	16	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>								<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>							<input checked="" type="checkbox"/>				<input checked="" type="checkbox"/>
5	2014	Microgrid : architectures and control	615						<input checked="" type="checkbox"/>			<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>			<input checked="" type="checkbox"/>					<input checked="" type="checkbox"/>			<input checked="" type="checkbox"/>	
6	2015	Métodos de Identificación dinámica	3	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	
7	2018	Identification of modal interaction and small signal stability in autonomous microgrid operation	18			<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>			<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		

8	2000	Identificación , Estimación y Control de Sistemas No-lineales mediante RGO	38				☒	☒	☐	☒		☒	☒			☒			☒	☒		☒	☒				
9	2010	Selective recursive kernel learning for online identification of nonlinear systems with NARX form	75	☒		☒		☒	☒			☒	☒			☒			☒	☒	☒			☒		☒	
10	2016	A literature review of Microgrids: A functional layer based classification	110	☒	☒						☒	☒			☒		☒					☒			☒	☒	
11	2019	Hybrid AC/DC microgrid test system simulation: grid-connected mode	4	☒						☒		☒		☒							☒		☒			☒	
12	2015	AC and DC technology in microgrids: A review	286	☒	☒								☒		☒							☒				☒	
13	2020	Redirección Y Optimización Del Consumo Eléctrico De Una Micro-Red Haciendo Uso Del Protocolo Data Distribution System.	0		☒							☒			☒				☒		☒	☒			☒	☒	
14	2020	Diseño De Micro-Redes Eléctricas Utilizando Energía Fotovoltaica Para El Sistema Auxiliar De Emergencia Energética En Edificaciones De Actividades Comerciales	0	☒	☒			☒			☒				☒							☒				☒	
15	2018	Microgrids and Smart Grids	1	☒		☒		☒														☒				☒	
16	2017	Impact analysis of distributed generation integration on distribution network considering smart grid scenario	3	☒		☒	☒	☒		☒		☒			☒		☒	☒						☒	☒		
17	2014	Microrredes basadas en electrónica de potencia: parte II: control de potencia activa y reactiva	5	☒					☒				☒		☒						☒		☒			☒	☒
18	2015	Tesis Desarrollo De Un Algoritmo De Interrelación Para Microrredes De Distribución Eléctrica	4	☒	☒			☒	☒		☒		☒	☒					☒			☒				☒	
19	2018	Energías renovables y generación distribuida.	1	☒	☒				☒				☒			☒	☒								☒	☒	
20	2017	Ubicación y operación eficiente de almacenadores de energía en micro-redes en presencia de generación distribuida	3		☒				☒			☒	☒		☒							☒	☒		☒		
21	2017	Ubicación y dimensionamiento de generación distribuida: una revisión TT - Location and sizing of distributed generation: a review	9	☒	☒			☒	☒		☒		☒		☒		☒	☒	☒					☒	☒		
22	2013	NARX model based nonlinear dynamic system identification using low complexity neural networks and robust H $\infty$ filter	36	☒		☒	☒	☒	☒	☒		☒	☒			☒		☒	☒		☒			☒	☒		☒
23	2003	Modelado de la micro-turbina en el sistema de distribución mediante estructuras NARX	1				☒	☒	☒				☒		☒		☒				☒			☒	☒		
24	2004	Set Membership identification of nonlinear systems	217	☒				☒	☒						☒							☒				☒	
25	2020	A novel strategy for dynamic identification in AC/DC microgrids based on ARX and Petri Nets	0			☒	☒	☒		☒		☒	☒		☒						☒	☒			☒		☒
26	2017	Predicción de potencia a corto plazo para plantas fotovoltaicas utilizando redes neuronales artificiales	0				☒	☒	☒		☒	☒		☒		☒		☒	☒	☒	☒			☒	☒		

27	2017	Modelado y simulacion de los actores de una Microrred	2	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>			<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>			<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		
28	2018	Planificación eficiente de redes inteligentes (smart grids) incluyendo la gestión activa de la demanda: aplicación a Ecuador	1	<input checked="" type="checkbox"/>				<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>			<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>			<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		
29	2019	Incorporation of Artificial Intelligence in a virtual basic twin of an industrial robot	0			<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>			<input checked="" type="checkbox"/>										
30	2019	Diseño de redes neuronales inteligentes para la realización de pronósticos en microrredes eléctricas	1			<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>			<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		
31	2020	Reduction of harmonic monitors and estimation of voltage harmonics in distribution networks using wavelet analysis and NARX	0			<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		
32	2019	Electrical Charge of Niamey City Modelisation by Neural Network	3				<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>			<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>			<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	
33	2018	A nonlinear autoregressive exogenous (NARX) neural network model for the prediction of the daily direct solar radiation	60			<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>								
34	2016	An Application of Non-Linear Autoregressive Neural Networks to Predict Energy Consumption in Public Buildings	91			<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>			<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
35	2000	Estudio de redes neuronales modulares para el modelado de sistemas dinámicos no lineales.	32				<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>			<input checked="" type="checkbox"/>			<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		
36	2000	Inversion control of non-linear systems with an inverse NARX model identified using genetic algorithms	19		<input checked="" type="checkbox"/>			<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>			<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	
37	2019	An ARX-Petri Nets algorithm for Active Identification of an AC / DC Microgrid Simulation	0		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>			<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	
38	2019	Incorporation of Artificial Intelligence in a virtual basic twin of an industrial robot	3				<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>			<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>			
39	2019	Diseño de redes neuronales inteligentes para la realización de pronósticos en microrredes eléctricas	0	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>						<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>			<input checked="" type="checkbox"/>						
40	2019	Reduction of harmonic monitors and estimation of voltage harmonics in distribution networks using wavelet analysis and NARX	0			<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>			<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		
41	2019	Electrical Charge of Niamey City Modelisation by Neural Network	0			<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>								
42	2018	A nonlinear autoregressive exogenous (NARX) neural network model for the prediction of the daily direct solar radiation	1					<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>									
43	2016	An Application of Non-Linear Autoregressive Neural Networks to Predict Energy Consumption in Public Buildings	2			<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>			<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	
44	2000	Estudio de redes neuronales modulares para el modelado de sistemas dinámicos no lineales	13			<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>		

45	2000	Inversion control of non-linear systems with an inverse NARX model identified using genetic algorithms	10			☒		☒	☒		☒		☒			☒	☒				☒	☒	☒				
46	2019	Hybrid AC/DC microgrid (HMG) test system simulation	11	☒	☒			☒	☒				☒			☒					☒	☒	☒				
47	2015	Modelización con Petri Net de una aplicación automática de diagnóstico y restauración de avería en sistema de distribución	0	☒		☒	☒			☒	☒				☒		☒	☒			☒	☒		☒			
48	2018	Localización de fallas en microredes eléctricas basado en un modelo Markoviano	2	☒					☒				☒			☒	☒				☒			☒			
49	2017	Multi-Criteria Optimization of the Deployment of a Grid for Rural Electrification Based on a Heuristic Method	0	☒	☒					☒		☒			☒		☒	☒					☒				
				24	17	21	17	26	32	12	17	23	27	17	6	22	18	8	27	30	16	13	18	34	20	16	14

## 10.2 Resumen de Indicadores.

