



Comité Nacional Paraguayo



Unión de Ingenieros de la ANDE

XII SEMINARIO DEL SECTOR ELECTRICO PARAGUAYO – CIGRÉ 25 y 26 de agosto de 2016

MÉTODO DE PREVISIÓN DE DEMANDA DE CORTO PLAZO A TRAVÉS DE REDES NEURALES ARTIFICIALES CON SISTEMAS INMUNOLÓGICOS ARTIFICIALES.

Autores: Ing. Ricardo Alonso, Ing. Alcides Chávez (ANDE)

Contacto:

**División de Distribución Regional Zona Sur
Administración Nacional de Electricidad**

Teléfono: (+595 71) 209260

e-mail: ricardo_alonso@ande.gov.py; alcides_chavez@ande.gov.py

Palabras Clave: Red Neuronal Artificial (RNA), Sistema Inmunológico Artificial (SIA), STLF (Short Term Load Forecast o Previsión de Demanda de Corto Plazo).

1- Resumen

Este trabajo trata de la aplicación de *Redes Neuronales Artificiales* (RNA) en la previsión de demanda de corto plazo. La red neuronal artificial ajustada considera informaciones de temperatura, humedad relativa del ambiente que se asignaron a la demanda de la red eléctrica del caso analizado. La comparación de los resultados obtenidos vía redes neuronales y el procedimiento utilizado actualmente en los centros de distribución, apuntan a mejoras significativas en la predicción de la demanda a corto plazo de la red de distribución y a mejorar la capacidad de respuesta en la planificación de remanejo de carga, disponibilidad de equipos y circuitos, etc.

2- Introducción

Una de las principales metas de la planificación es la disminución del impacto de la incertidumbre relacionada al futuro de cualquier organización.

La búsqueda de métodos basados en modelos de predicción de corto, mediano y largo plazo pasó a despertar el interés de investigadores en las más diversas áreas como economía, mercadotecnia, finanzas e ingeniería. Los modelos tradicionales de previsión, basados en

herramientas matemáticas y estadísticas, son ampliamente utilizados. Entretanto, gracias al avance tecnológico observado en los últimos 20 años, las investigaciones fueron direccionadas hacia la utilización de herramientas más modernas y eficientes para desempeñar la tarea de realizar predicciones.

Aunque hayan sido ampliamente utilizados métodos avanzados como algoritmos genéticos, lógica difusa y redes neuronales, los modelos de apoyo a la decisión basados en optimización son los que representan el futuro de los sistemas de información. Estos modelos constan de tres etapas a) formulación, en la cual se genera el modelo en sí, b) solución, que se refiere al algoritmo utilizado y c) análisis, que se refiere a la evaluación e interpretación del modelo para un conjunto de soluciones.

Hay un creciente interés en la meta-heurística para la solución de problemas estocásticos empleando técnicas como algoritmos genéticos, lógica difusa, modelado probabilístico, redes neuronales, etc. En ese sentido, uno de los sectores que despierta el interés de los investigadores es el de la energía eléctrica; específicamente, la previsión de la demanda.



XII SEMINARIO DEL SECTOR ELECTRICO PARAGUAYO – CIGRÉ 25 y 26 de agosto de 2016

Una de las principales características de la energía eléctrica, es que una vez generada, debe ser distribuida y consumida, ya que no puede ser almacenada. Por lo tanto, debe obtenerse un perfecto equilibrio entre oferta y demanda. El acelerado crecimiento de la demanda de energía eléctrica, trajo como consecuencia el aumento en la investigación en el área de la planificación de los sistemas de energía.

Este trabajo se enfoca en la previsión del comportamiento de la carga que permita a los centros de distribución, con poco margen de error, predecir cuál será el valor más probable que alcanzará en corto plazo y cuál será la estrategia de operación a ser adoptada en tal situación. Se propone describir el método de RNA como válido para la previsión de carga de corto plazo y su importancia para la programación, análisis de contingencias, operación y mantenimiento del sistema de potencia o distribución. También, la importancia de los Algoritmos Evolutivos (Sistemas Inmunológicos Artificiales) como método de optimización de los pesos asignados a los componentes neuronales de la RNA.

3- Red Neuronal Artificial (RNA)

Las RNA han recibido últimamente mucha atención en el ámbito de STLF y un gran número de artículos han reportado experimentos exitosos con ellas. Dada una muestra de vectores de entrada y de salida, las RNA son capaces de mapear automáticamente las relaciones entre ellos. Las RNA “aprenden” estas relaciones y almacenan este aprendizaje en sus parámetros. Puede probarse que las RNA son particularmente útiles cuando se posee una gran cantidad de datos, pero poco o ningún conocimiento previo acerca de las leyes que rigen el sistema que genera tales datos.

La neurona artificial es la unidad básica de una RNA. Esta recibe información numérica desde

un cierto número de nodos de entrada, la procesa internamente y suministra una salida. Este proceso es realizado en dos etapas. En la primera etapa, los valores de entrada son combinados linealmente, luego en la segunda etapa, el resultado es usado como el argumento de una función de activación o transferencia no lineal. La combinación lineal emplea pesos, que son atributos de cada conexión y un término de umbral constante. Las RNA están compuestas de varias neuronas que operan simultáneamente. Generalmente, una red es entrenada de manera que un conjunto particular de entradas origine una salida específica (objetivo). Es decir, los pesos que unen los diversos nodos de una RNA y los umbrales de cada neurona son ajustados comparando la salida de la red con la salida objetivo, hasta que ambas salidas sean prácticamente iguales.

La manera en que las neuronas son organizadas define la arquitectura de la red.

La arquitectura de RNA seleccionada es la denominada Perceptrón Multicapa (MLP), con alimentación hacia adelante, en que las neuronas son organizadas en capas. Las neuronas en cada capa pueden compartir las mismas entradas, pero no están conectadas unas con otras en la misma capa. Si la estructura es con alimentación hacia delante (feed-forward) las salidas de una capa son usadas como las entradas de la capa siguiente. Las capas entre los nodos de entrada y la capa de salida son llamadas capas ocultas. Se procedió así debido a que se considera que dicha arquitectura es la de uso más extendido en el contexto de STLF. Para validación de los resultados de las RNA se recurrió a la plataforma MatLab[®] Neural Network Toolbox[™]

4- Características de las Series de Demanda

El principal insumo de la serie temporal utilizada, es la demanda asociada a una carga en el horario del día en que esta se produce.

XII SEMINARIO DEL SECTOR ELECTRICO PARAGUAYO – CIGRÉ 25 y 26 de agosto de 2016

Las series temporales de demanda exhiben importantes niveles de estacionalidad; así, la demanda en una hora determinada depende no solo de la demanda en la hora previa, sino también de la demanda a la misma hora del día anterior y de la carga en la misma hora del día de la misma denominación de la semana previa. Las series de demanda muestran tendencias, usualmente positiva o creciente, dinámicas de corto plazo, dependencia de eventos relacionados al calendario y efectos no lineales de variables meteorológicas. La tendencia en la demanda está usualmente asociada a factores económicos y demográficos, mientras que las otras características están relacionadas con variaciones climáticas y del comportamiento humano.

Factores derivados de variables meteorológicas como las temperaturas diarias máxima y mínima, así como la humedad relativa del ambiente, han sido empleados como variables exógenas para mejorar el pronóstico de la demanda [1].

5- Sistemas Inmunológicos Artificiales

Varias técnicas de computación evolutiva se han empleado para resolver problemas de optimización. Estas técnicas imitan los sistemas o procesos biológicos, tales como el sistema nervioso, la meiosis y el sistema inmunológico, de una manera computacional [2]

El sistema inmunológico es un complejo de células, moléculas y órganos que representan un mecanismo de identificación capaz de percibir y combatir la disfunción de la propia célula y la acción de los microorganismos infecciosos exógenos. Reconoce una variedad casi ilimitada de células y sustancias extrañas infecciosas, distinguiéndolos de esas células no infecciosas nativas [3][4].

Los Sistemas Inmunológicos Artificiales (SIA) poseen muchas características interesantes para resolver problemas de optimización. Ya han sido aplicados a la robótica, el control

adaptativo, optimización, sistemas multi-agente y los enfoques de redes neuronales, sistemas basados en el gradiente, minería de datos, clasificación de imágenes y despacho óptimo [2].

El SIA se utiliza en este trabajo porque presentan las siguientes características: carácter único, reconocimiento de los cuerpos extraños, detección de anomalías, detección imperfecta (tolerancia de ruido), aprendizaje por refuerzo, la memoria y reconocimiento de patrones[2].

En el ámbito de los sistemas eléctricos de potencia han sido utilizados en reconfiguración de sistemas eléctricos de distribución [3], recarga optimizada de vehículos eléctricos [5], despacho económico [6] y otros.

En este estudio, el principio de selección clonal basado en los SIA ha sido desarrollado para optimizar los pesos de las neuronas en la RNA con el objetivo de minimizar el error medio porcentual (MAPE) entre la salida estimada y la real.

$$MAPE = \frac{\sum_1^N (t_{pi} - O_{pi})}{N} \quad (1)$$

Donde N es el número de muestras de entrenamiento, t_{pi} y O_{pi} son la salida estimada y O_{pi} es el valor real.

6- Metodología propuesta para el trabajo

Este trabajo propone la utilización de una RNA monocapa de 17 neuronas en la capa oculta y una neurona en la capa de salida con alimentación hacia adelante (feed-forward). Esta estructura es relativamente sencilla, sin embargo presenta muy buenos resultados según estudios anteriores [1]. Estructuras más complejas son utilizadas (perceptron multicapas – Fig. 1) como en [7]. Como se menciona más arriba, estas neuronas están conectadas con las entradas y en este caso a una salida, por medio de pesos lo que constituye una abstracción de la sinapsis neuronal tal como ocurre en los procesos del cerebro de los vertebrados. El

XII SEMINARIO DEL SECTOR ELECTRICO PARAGUAYO – CIGRÉ
25 y 26 de agosto de 2016

objetivo tras la predicción de la demanda es primeramente obtener un conjunto de pesos adecuados, de modo a que el MAPE sea minimizado. Estos pesos son obtenidos en un proceso denominado “aprendizaje”.

Como función de transferencia en la primera capa es utilizada la función sigmoidea, que es la más empleada en este tipo de problemas, y como función de transferencia en la salida es utilizada la función lineal o identidad [7][8].

Para el aprendizaje de la RNA es utilizada una heurística, en este caso un Sistema Inmunológico Artificial (SIA) que provee un buen mecanismo de búsqueda de soluciones en un espacio multidimensional como es este caso.




Fig. 1: Arquitectura de una Red Neuronal Multicapas

En la capa de entrada son ingresados los siguientes datos:

- a. Hora del día en el cual será estimada la demanda.
- b. Día de la semana.
- c. Temperatura de bulbo seco.
- d. Punto de rocío.
- e. Promedio de la demanda del día anterior.
- f. Demanda del día anterior en la misma hora en la cual se desea estimar la demanda.
- g. Demanda de semana anterior en la misma hora en la cual se desea estimar la demanda.
- h. Si es feriado o no.

En total son 8 variables de entrada.

Para la implementación del SIA se utilizaron los siguientes parámetros:

A. Población inicial

Al principio no existe un conjunto de pesos a ser utilizados entre las entradas y las neuronas de la capa oculta, ni tampoco entre esta capa y la salida. Entonces son generados un conjunto de pesos codificados binariamente en un elemento de 16 bits, donde los pesos son determinados por la siguiente expresión:

$$w_j^i = \frac{w_{10} \times (R_s - R_i)}{2^{16} - 1} + R_i \quad (2)$$

Donde:

w_j^i es el j-ésimo peso de la capa i.

w_{10} es la expresión decimal del vector binario (16 bits) hallado aleatoriamente.

R_s y R_i son valores inferior y superior del rango de variación de los pesos.

El tamaño de cada anticuerpo, por otro lado es:

$$Lbits = [16] \times [(NN + 2) \times Ne + 1] \quad (3)$$

Siendo NN el número de Neuronas de la capa oculta y Ne el numero de variables.

B. Hiper mutación.

Este proceso comprende la selección de los anticuerpos más afines, clonación en proporción directa a su afinidad y mutación de cada anticuerpo clonado en función inversa a su afinidad.

XII SEMINARIO DEL SECTOR ELECTRICO PARAGUAYO – CIGRÉ
25 y 26 de agosto de 2016

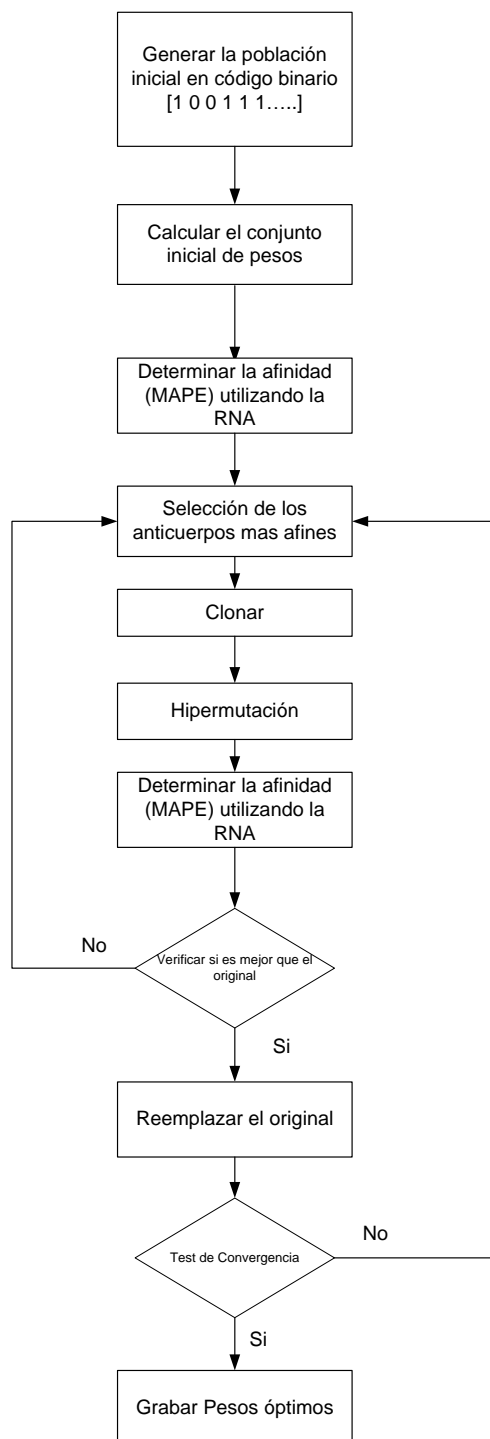


Fig. 2: Flujograma para la determinación de pesos óptimos.

C. Determinación de pesos utilizando RNA y SIA – Algoritmo propuesto.

El flujograma del algoritmo propuesto puede observarse en la Fig. 2. Mediante esta secuencia se “entrena” a la RNA de modo que el error MAPE, sea mínimo.

Estos pesos óptimos serán utilizados para validar posteriormente la RNA.

7- Resultados y conclusión

Para entrenar a la RNA fue utilizado un conjunto de datos obtenidos de la página de Matlab®, correspondientes a la red de ISO New England Inc., correspondientes a los años 2004 a 2008.

Fueron utilizados los siguientes parámetros de simulación para el entrenamiento de la RNA.

- a) Población inicial = 1000 anticuerpos
- b) Numero de Clones = 10
- c) Selección de los 20 anticuerpos más afines
- d) 17 neuronas en la capa oculta.
- e) Probabilidad de mutación = 0.05 (mínimo)
- f) 150 iteraciones
- g) Criterio de parada: numero de iteraciones

Es interesante ver como el error va disminuyendo a medida que transcurren las iteraciones, lo que permite inferir que el SIA está procurando los pesos más adecuados para mejorar el MAPE (Fig. 3).

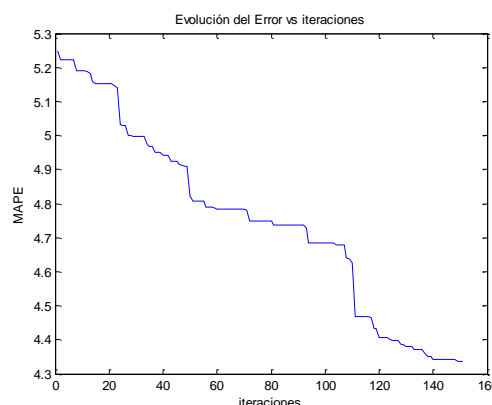


Fig. 3: Evolución del Error (MAPE) vs iteraciones.

XII SEMINARIO DEL SECTOR ELECTRICO PARAGUAYO – CIGRÉ
25 y 26 de agosto de 2016

Para validar el modelo fueron utilizados los siguientes datos de entrada:

Tabla I: Datos de entrada a la RNA

T°C	Tº Rocio	Hora	Día	Feriado
33	-3	24	5	1
30	-10	1	6	1
22	-17	2	6	1
22	-20	3	6	1
18	-27	4	6	1
11	-27	5	6	1
7	-30	6	6	1
4	-34	7	6	1
0	-37	8	6	1
0	-44	9	6	1
0	-51	10	6	1
4	-54	11	6	1
7	-57	12	6	1
15	-54	13	6	1
18	-51	14	6	1
22	-51	15	6	1
26	-47	16	6	1
22	-47	17	6	1
15	-47	18	6	1
11	-47	19	6	1
7	-47	20	6	1
4	-47	21	6	1
4	-51	22	6	1
0	-51	23	6	1
-4	-51	24	6	1

Tabla II: Datos de Demandas.

Prev. Semana	Prev. Día	Prev. Media	Load
15879	16088	18931	16541
14733	15076	18949	15507
14164	14620	18969	15090
13923	14446	18990	14946
13908	14466	19011	14972
14200	14839	19035	15397
15141	16109	19057	16644
16798	18596	19084	19239
18411	20111	19115	20847
19670	20237	19152	21118
20692	20268	19191	21205
21216	20259	19234	21271
21375	20122	19278	21172
21191	19867	19322	20913
20847	19706	19363	20688
20586	19534	19401	20446
20620	19604	19439	20508
21767	20816	19468	21508
22818	22308	19490	22818
22318	22294	19506	22672
21537	21741	19523	22154
20679	21042	19542	21501
19549	19769	19574	20528
18036	18166	19615	19136
16439	16541	19667	17785

Con estos datos se obtuvo la previsión que puede observarse en la Fig. 4.

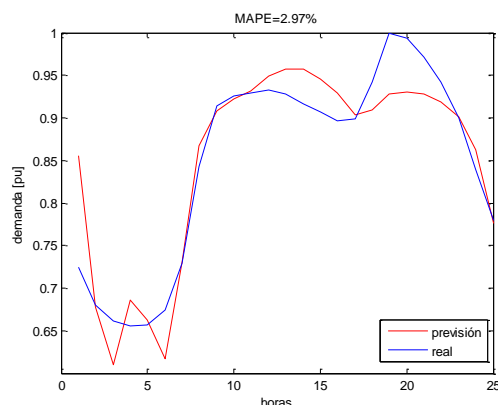


Fig. 4: Validación del modelo

En **conclusión**, podemos afirmar que el método de entrenamiento de la RNA por medio del principio de selección clonal (SIA), es una herramienta válida. La simplicidad de programación y la cantidad de parámetros necesarios para ejecutar el algoritmo frente a

XII SEMINARIO DEL SECTOR ELECTRICO PARAGUAYO – CIGRÉ 25 y 26 de agosto de 2016

otras herramientas de previsión, es una ventaja adicional.

Sin embargo, el objetivo de probar el desempeño con datos del sistema de la ANDE es aún una tarea pendiente, lo cual será realizado como complemento a este trabajo, esperando replicar la validez de los resultados y el método como aplicable a la previsión de la demanda de las redes de distribución.

El tiempo computacional es un factor a considerar, ya que el proceso de aprendizaje demora considerablemente. Sin embargo como la tarea puede ser llevada anticipadamente, esto no representa una limitación que inviabilice la metodología.

Queda pendiente explorar RNAs más complejas como las constituidas por perceptrones multicapa. Es de esperar que esta complejidad adicional agregue más precisión a la rutina.

8- Bibliografía

- [1] O. Barboza, «Automatización de previsión de demanda horaria de potencia eléctrica en el Sistema Interconectado Nacional,» *Rev. cient. UCSA*, vol. Vol.1, nº 01, Diciembre 2014.
- [2] R. L. J. Mendonza, D. Morales, E. López, P. Dessante y R. Moraga, «Minimal Loss Reconfiguration Using Genetic Algorithms with Restricted Population and Adressed Operators: Real Application,» *IEEE Transactions on Power Systems*, pp. vol. 21, no. 2, 948-954, 2002.
- [3] R. Alonso, D. Oliveira y A. Zambroni de Souza, «Artificial Immune Systems Optimization Approach for Multiobjective Distribution System Reconfiguration,» *IEEE Transactions on Power Systems*, pp. 840 - 847, 2015.
- [4] D. P. Bernadon, V. J. Garcia, Ferreira, A. S. Q. y L. N. Cunha, «Multi-criteria Distribution Network Reconfiguration Considering Sub transmission Analysis,» *IEEE Transactions on Power Delivery*, pp. ,vol. 25, no. 4, pp. 2684-2691, 2010.
- [5] I. Lima, D. Oliveira, F. Oliveira, D. L. y A. Zambroni de Souza, «Electric and Plug-in Hybrid Vehicles Recharge in Distribution Power Systems,» de *11th International Conference on Environment and Electrical Engineering*, Itália, 2012.
- [6] T. K. A. Ahman, Z. M. Yasin y W. N. W. Abdullah, «Artificial-Immune-Based for Solving Economic Dispatch In Power System,» de *National Power & Energy Conference (PECon) Proceedings*, Kuala Lumpur, Malaysia, 2004.
- [7] Z. A. Bashir y M. E. El Hawary, «Applying Wavelets to Short - Term Load Forecasting Using PSO-Based Neural Networks,» *IEEE Transactions on Power Systems*, vol. 24, nº 01, pp. 20-27, 2009.
- [8] R. Benítez, D. Cattani, I. Benítez y A. Arce, «Aplicación de Redes Neuronales Artificiales en la Previsión del Suministro Energético de la Central Hidroeléctrica de Itaipú al Sistema Eléctrico Paraguayo,» *Artículos Científicos*, 2008.