

Aplicación de Redes Neuronales Artificiales en la Previsión del Suministro Energético de la Central Hidroeléctrica de Itaipú al Sistema Eléctrico Paraguayo

Ramón Benítez¹, Daniel Cattani¹, Ivo Benítez¹, Anastacio Arce²

Universidad Nacional del Este - Facultad Politécnica

¹rbenitezgodoy@yahoo.com.br

²arce@itaipu.gov.py

Resumen: Este trabajo trata de la aplicación de *Redes Neuronales Artificiales* (RNA) para el modelado del suministro de energía de la Central Hidroeléctrica de Itaipú Binacional (Itaipú) al sistema eléctrico paraguayo. La red neuronal artificial ajustada considera informaciones de temperatura y datos de suministros anteriores. La comparación de los resultados obtenidos vía redes neuronales y el procedimiento actual apuntan a mejoras significativas en la predicción del suministro energético de Itaipú al sistema eléctrico paraguayo.

Palabras Claves: Programación de la Operación, Operación en Tiempo Real, Previsión de Carga de Corto Plazo, Redes Neuronales Artificiales, Red MLP-BP.

Abstract: This work is concerned with the application of *Artificial Neural Network* (ANN) for modeling of electrical energy supply of Itaipú Hydro plant to the Paraguayan Electrical Power System. The ANN adjusted consider temperature and past load supplied information. Comparison between actual procedure and the NNA methodology appoint an important improvement in the prediction of energy supply of Itaipú to the Paraguayan Electrical Power System.

Key words: Scheduling Operation of Electrical Power Systems, Real Time Operation, Short Term Load Forecasting, Artificial Neural Network, Artificial Neural Network ML-BP.

1. Introducción

La producción de energía eléctrica es el resultado de un proceso que se inicia en las etapas del planeamiento de la operación de largo, medio, corto plazo y concluye en la operación en tiempo real. En cada una de las etapas del planeamiento se busca atender la demanda de energía eléctrica observando criterios de seguridad y de economía.

El tipo de previsión de la demanda de energía varía conforme a la etapa del planeamiento. El planeamiento de la operación de largo y medio plazo requiere una previsión del volumen o el total de la demanda de energía. El periodo de las previsiones en esta etapa puede ser anual o mensual. Estas previsiones son aplicadas en la evaluación de la capacidad de generación, transmisión y programas de mantenimiento de los equipos de estos sistemas. Son también usadas para la definición de los contratos de compra-venta de energía.

En el planeamiento de corto plazo, programación y operación en tiempo real, se

requiere una previsión de la demanda observando inclusive detalles de su forma, valores máximos y mínimos. Las predicciones de corto plazo, con periodicidad horaria y en intervalos menores inclusive, son utilizadas en la operación de los sistemas eléctricos de potencia para el control de carga-frecuencia, control de tensión, despacho óptimo de generación y de unidades generadoras. Entonces, si el comportamiento de la carga no presenta desvíos significativos con relación a los valores previstos, la programación de la operación elaborada con base en la previsión de carga estimada para el periodo en consideración, será una referencia válida para la operación en tiempo real [1].

La literatura sobre modelos de previsión de carga es extensa. La metodología efectiva de previsión de carga es aquella que consigue extraer de los datos históricos sus características básicas, las cuales se supone permanecerán válidas para el futuro. Las metodologías más aplicadas son aquellas que utilizan técnicas estadísticas, tales como las técnicas de regresión

lineal y series temporales. Sin embargo, a partir de la década del 90 las redes neuronales artificiales (RNA) pasaron a ocupar un lugar importante entre los métodos de previsión de carga con resultados generalmente mejores que los modelos estadísticos. En muchos casos, los modelos híbridos, compuestos por RNA y modelos estadísticos, son superiores a los modelos estadísticos y a los modelos RNA [2].

En este trabajo es presentado un modelo de previsión del suministro de energía eléctrica de la Central Hidroeléctrica de Itaipú al sistema eléctrico paraguayo. El modelo utiliza redes neuronales artificiales que tiene como datos de entrada informaciones relacionadas al mes, día de la semana, hora, histórico del suministro energético y temperatura.

2. Suministro energético de Itaipu al sistema eléctrico paraguayo

En el año 2006, la central hidroeléctrica de Itaipú Binacional fue responsable por la atención del 26 y 94 %, respectivamente, de la demanda de energía eléctrica de la región sudeste brasileño y el sistema eléctrico paraguayo.

Itaipú es una central hidroeléctrica de pasada, con una capacidad mínima de regulación de los caudales afluentes. Además de las limitaciones asociadas a su capacidad mínima de regulación, aguas abajo existen restricciones que limitan las variaciones de su descarga a nivel horario y diario. Por un acuerdo firmado por Paraguay, Brasil y Argentina, con el objeto de mantener las condiciones mínimas de navegabilidad aguas abajo de Itaipú, fue establecido que las variaciones del nivel del Río Paraná en la frontera de los tres países mencionados no deben superar los dos metros diarios y medio metro horario. Estas condiciones establecen una restricción importante en la capacidad de Itaipú para acompañar las variaciones de la carga, principalmente la punta de la carga.




Figura 1 – Fuente de suministro del sistema eléctrico paraguayo.

En el sistema eléctrico paraguayo, a pesar de contar con otras fuentes de generación, Itaipú continúa siendo la principal fuente de suministro. Acaray es un aprovechamiento hidroeléctrico de 180 MW de propiedad de la ANDE (Administración Nacional de la Electricidad), órgano estatal que tiene el monopolio de la generación, transmisión, distribución y comercialización de la electricidad en el Paraguay. Yacyretá es una central hidroeléctrica binacional de Paraguay y Argentina, cuya capacidad instalada es de 2600 MW. El suministro energético de Yacyretá al Paraguay es posible apenas en cargas aisladas debido a que la operación conjunta de Yacyretá, el sistema eléctrico paraguayo, Acaray e Itaipu será factible luego de superadas las dificultades de control asociados a la interconexión de dos grandes sistemas, como lo son los sistemas eléctricos brasileño y argentino, con diferentes valores de estatismo de sus unidades generadoras. La figura 1 muestra las principales fuentes de suministro del sistema eléctrico paraguayo.

2.1. Característica de la carga del sistema eléctrico paraguayo

La carga del sistema eléctrico paraguayo posee un bajo factor de carga con fuerte presencia del tipo de consumidor residencial y comercial. Estas características definen un perfil de la curva de carga con grandes variaciones y fuerte correlación con las condiciones climáticas. La figura 2 muestra el perfil de la demanda del sistema eléctrico paraguayo en el verano e invierno. Se verifica una disminución significativa de los valores de la demanda en el periodo de invierno y un desplazamiento del inicio de la hora de punta. Las temperaturas promedio fueron 29 y 11 °C para los días 15/12/06 y 11/05/07, respectivamente.




Figura 2 – Suministro energético de Itaipú al Sistema Eléctrico Paraguayo.

2.2. Procedimientos para la programación del suministro energético de Itaipu al sistema eléctrico paraguayo

La programación es la última etapa del planeamiento que antecede a la operación en tiempo real. En esta etapa es compatibilizada la operación hidroenergética con la operación eléctrica. El objetivo de la programación es definir un programa de operación que sirva de referencia a la operación en tiempo real. Cada día es elaborado este programa tomando en consideración la operación del día siguiente y días subsecuentes, como los finales de semana y feriados.

El procedimiento para la elaboración del programa de suministro de Itaipú a los sistemas eléctricos paraguayo y brasileño sigue los siguientes pasos:

- Evaluación de la disponibilidad energética, en función a los caudales afluentes aguas arriba y aguas abajo de Itaipú, disponibilidad para la operación de unidades generadoras, capacidad de transformación y de transmisión.
- Evaluación de la capacidad de potencia en función a las restricciones hidroenergéticas.
- Informe a los sistemas eléctricos paraguayo y brasileño de la disponibilidad de potencia y energía.
- Ajuste de las demandas horarias de los sistemas eléctricos paraguayo y brasileño para compatibilizarlos a las restricciones hidroenergéticas y de disponibilidad energética de Itaipú.

Resultado de este proceso es el programa de suministro que es entregado a la operación en tiempo real para su ejecución.




Figura 3 – Suministro programado y realizado.

En tiempo real, la operación busca seguir aquello que fue definido en la programación. Si el equilibrio entre la generación y la carga se verifica por debajo de los valores programados, esto puede significar reprogramaciones de la operación hidroenergética como vertimientos, aumento del suministro al Brasil o simplemente aumento de la acumulación del volumen energético en el embalse cuando el desvío no comprometerá los límites de capacidad del embalse o las variaciones máximas horaria o diaria aguas abajo de Itaipú. Si el desvío de la demanda ocurre con valores superiores a lo programado, esto puede ocasionar caída de la frecuencia, el comprometimiento de los límites operativos del embalse o de las variaciones máximas horarios o diarias aguas abajo de Itaipú. El control de esta situación puede significar la disminución del suministro energético al Brasil o simplemente el aumento de la generación si existiere reserva u holgura en la disponibilidad energética. La figura 3 muestra la curva de suministro programado y realizado de Itaipú al sistema eléctrico paraguayo en un día típico.

Debido a la importancia del suministro energético a los sistemas eléctricos brasileño y paraguayo, a las restricciones asociadas a la operación hidroenergética de la Central de Itaipú, a la necesidad de mantener un margen de reserva para la regulación, límites de equipamientos y del propio sistema eléctrico, que deben ser observados, se requiere de una buena previsión del comportamiento de la carga.

3. Previsión de carga vía RNA

1.1. Redes neuronales artificiales

Una red neuronal artificial RNA puede ser definida como un sistema altamente conectado

de procesadores elementales llamadas neuronas, las cuales procesan informaciones a través de su estado dinámico en respuesta a señales externas. Poseen este nombre porque son inspiradas en modelos biológicos, es decir, ellas están compuestas por elementos que reproducen algunas funciones elementales de la neurona biológica. La figura 4 muestra una estructura genérica de una red frecuentemente usada.




Figura 4 – Estructura de una red.

Las neuronas están conectadas unas con otras. Una neurona puede tener múltiples entradas pero una única salida. La entrada de una neurona puede ser oriunda de una señal externa o la salida de otra neurona. Copias de la salida simple de una neurona puede ser la entrada de muchas otras neuronas en la red. A las diferentes conexiones, *sinapsis*, de las neuronas están asociados unos pesos, conforme se puede apreciar en la figura 5 a. Cuando la suma de los pesos de entrada de una neurona excede un valor, la neurona es activada para producir una señal de salida. Las funciones de activación más utilizadas son la tangente sigmoidea y lineal unitaria, por su flexibilidad y amplio rango de resultados que ofrecen, conforme se puede apreciar en las figuras 5b y 5c, respectivamente.




Figura 5 – Esquema de una neurona artificial.

Para que una red neuronal descubra las relaciones no lineales entre dos conjuntos de datos hay que *entrenarla*.

1.2. Entrenamiento de las redes neuronales artificiales

El algoritmo *backpropagation* es el método de aprendizaje más frecuentemente utilizado en el entrenamiento de las redes. Este algoritmo de aprendizaje es una generalización de la regla de corrección de error de Widrow-Hoff. El error es la diferencia entre la salida que proporciona la RNA y la salida que se pretende obtener. Los diferentes pesos de las conexiones de las neuronas son corregidos mediante iteraciones que pretenden minimizar el error.

Con el proceso de aprendizaje por medio de ejemplos, de manera a aprender el comportamiento básico del sistema que se pretende modelar, las RNA han conseguido excelentes resultados en el área de previsión de carga.

El padrón clásico de aplicación de RNA en la previsión de carga sigue la siguiente secuencia. En una primera fase la red es entrenada a partir de los datos históricos de la carga e informaciones relacionadas al clima. Luego del entrenamiento, se efectúa la previsión de carga propiamente dicha. Dos interrogantes emergen aquí, la selección de un conjunto de datos, tan pequeño cuanto posibles, de modo a encontrar la representación deseada y la propiedad intrínseca de generalización de las RNA, es decir, la habilidad de interpolar y extrapolar a partir de un número finito de ejemplos [3, 4].

4. Descripción del modelo

En este ítem son presentados los procedimientos adoptados para el entrenamiento de las redes destinados para la previsión del suministro de Itaipú al sistema eléctrico paraguayo, a ser utilizados en la fase de programación y en la operación en tiempo real.

4.1 Tratamiento de los datos

Los datos disponibles para el modelado del comportamiento del suministro de Itaipú al sistema eléctrico paraguayo fue separado en tres conjuntos: un conjunto para entrenamiento, otro de validación y el último para pruebas. Antes, sin embargo, estos datos pasaron por un tratamiento que consistió en:

- Filtrado, a través de la eliminación de aquellos datos que huyen de los padrones característicos y que son oriundos de errores en los registros o a consecuencia de redistribución o corte de cargas en el sistema eléctrico paraguayo. En los casos de ausencia de datos, por ejemplo de temperatura, estos fueron estimados por interpolación directa. El proceso de análisis de los datos es efectuado a través de una inspección visual.
- Normalización de los datos a través de una transformación lineal en el intervalo $[-1, +1]$, asignando -1 al mínimo y $+1$ al máximo de cada variable. Para clasificar los días de la semana fue asignado el valor $+1$ para los días normales, en términos de comportamiento de la carga, que va de martes a sábado. Fue asignado 0 para los días lunes y -1 para los días domingos y feriados.

- Ordenación aleatoria de los datos del conjunto de entrenamiento, para minimizar algún efecto de tendencia temporal entre los mismos. Así también, el conjunto de validación fue ordenado aleatoriamente por obtenerse mayor capacidad de generalización en los resultados de la red. Al conjunto de prueba fue mantenida su ordenación cronológica.

4.2. Entrenamiento de la red

El método con mejor resultado de aplicación de la red neuronal para la previsión del suministro horario de Itaipú al sistema eléctrico paraguayo, a ser utilizado en la operación en tiempo real, es el dinámico con actualizaciones horarias. Este abordaje consiste en obtener las previsiones sucesivamente utilizando las previsiones de las horas anteriores.

El modelo ajustado para la fase de programación está basado en el método estático, en el cual las previsiones son obtenidas simultáneamente para las próximas 24, 72 o 120 horas, para el día siguiente, finales de semanas y feriados prolongados como semana santa, respectivamente.

La red adoptada en los dos modelos fue la Perceptrón Multicapa (MLP – Multi Layer Perceptron) con dos capas escondidas. Las redes fueron implementadas utilizando las herramientas del Matlab 6.5. El algoritmo de entrenamiento supervisado que registró mejores resultados es el *backpropagation* de Levenberg Marquart. El proceso de entrenamiento a través del conjunto de entrenamiento es acompañado por el conjunto de datos de validación, permitiendo que el entrenamiento sea realizado mientras el error de la validación disminuya junto con el error de entrenamiento. El proceso de entrenamiento finaliza cuando el error de la validación comienza a desprenderse de la tendencia de disminución y comienza a aumentar, como un síntoma de que la red está siendo súper entrenada y perdiendo su capacidad de generalización. Este proceso es denominado validación cruzada [5].

El modelo ajustado para la previsión del suministro con discriminación horaria y horizonte de 24 horas hasta 120 horas, a ser aplicado en la programación de la operación, es una red MLP-BP con 17 neuronas en la entrada,

13 y 7 neuronas en la 1ª. y 2ª. capa escondida, respectivamente, y una neurona en la capa de salida correspondiente a la carga a ser prevista.

Los siguientes datos son variables de entrada de la red:

t, la hora en que se pretende prever la carga, de 1 a 24.

$\sin 2_t/24$;

$\cos 2_t/24$;

d, día de la semana, de 1 a 7;

clasificación del tipo de día, de -1, 0 y +1;

m, mes del año, de 1 a 12;

c-5s, carga 5 semanas antes;

c-4s, carga 4 semanas antes;

c-3s, carga 3 semanas antes;

c-2s, carga 2 semanas antes;

c-1s, carga 1 semana antes;

T-5t, temperatura 5 horas antes;

T-4t, temperatura 4 horas antes;

T-3t, temperatura 3 horas antes;

T-2t, temperatura 2 horas antes;

T-1t, temperatura 1 hora antes;

Tt, temperatura hora actual;

Las funciones de activación de las dos capas escondidas es tangente sigmoidea, mientras que en la capa de salida fue una función lineal.

Es importante señalar que los datos de temperatura utilizados se refieren a los registros de temperatura horaria de Asunción, donde está concentrada la mayor parte de la carga del sistema eléctrico paraguayo.

La red MLP-BP ajustada para la previsión de carga en la operación en tiempo real tiene la siguiente arquitectura: en la entrada, 23 neuronas; en las capas escondidas, 13 y 7 neuronas; y en la salida, una neurona correspondiente a la carga a ser prevista.

Similarmente al modelo destinado a la programación, las funciones de activación fueron la tangente sigmoidea en las capas escondidas y una función lineal en la capa de salida.

Los siguientes datos son variables de entrada de la red:

t, la hora en que se pretende prever la carga, de 1 a 24.

$\sin 2_t/24$;

$\cos 2_t/24$;

d, día de la semana, de 1 a 7;

clasificación del tipo de día, de -1, 0 y +1;

m, mes del año, de 1 a 12;

c-1s, carga 1 semana antes;

c-1d, carga 1 día antes;

c-5t, carga 5 horas antes;

c-4t, carga 4 horas antes;

c-3t, carga 3 horas antes;

c-2t, carga 2 horas antes;

c-1t, carga 1 hora antes;

T-1s, temperatura 1 semana antes;

T-1d, temperatura 1 día antes;

T-5t, temperatura 5 horas antes;

T-4t, temperatura 4 horas antes;

T-3t, temperatura 3 horas antes;

T-2t, temperatura 2 horas antes;

T-1t, temperatura 1 hora antes;

Tt, temperatura de la hora actual;

D, diferencia entre la temperatura de la hora a prever y 1 hora antes de la misma.

D(c-1t), diferencia entre la carga actual y una hora antes.

Los datos utilizados para el modelado de la red corresponden al periodo de 01 de abril de 2006 hasta 25 de marzo de 2007.

5. Resultados numéricos

Como índice de desempeño de los modelos fue utilizado el Error Medio Porcentual Absoluto o MAPE (*Mean Absolute Percent Error*) definida por la siguiente ecuación:

$$MAPE = \frac{1}{NF} \sum_{i=1}^{NF} APE_i \quad (1)$$

$$APE_i = \left| \frac{X_i - \hat{f}_i}{\hat{f}_i} \right| \times 100 \% \quad (2)$$

donde

X_i Es la carga real verificada

$\hat{f}_i$ Es la carga prevista

NF Es el número de previsiones horarias

Con el modelo de previsión destinado para la programación fue obtenido un error medio porcentual absoluto (MAPE) de 3,85 %, para un periodo de simulación de 1.200 horas. El MAPE en el modelo destinado para la operación en tiempo real es de 2,33 %, para un periodo de simulación equivalente de 1.200 horas.

En la siguiente secuencia de figuras se pueden verificar los valores del suministro energético (MWh/h) de Itaipu al sistema eléctrico paraguayo, correspondiente a los valores reales observados y a los resultados obtenidos por los 2

modelos de RNA, ajustados para su aplicación en la programación y en la operación en tiempo real. Las figuras numeradas sin el subíndice a, muestran la curva del programa de suministro obtenido por la metodología actual. En la parte superior de cada figura se presenta el error MAPE verificado en la simulación, tomando como referencia los valores verificados de suministro diario o fin de semana.




Fig. 6 - Comparación del día jueves 15/03/07, módulo destinado para la programación.




Fig. 6a - Comparación del día jueves 15/03/07, módulo destinado a la operación en tiempo real.




Fig. 7 Comparación del día viernes 16/03/07 módulo de programación.




Fig. 7a - Comparación del día viernes 16/03/07, módulo destinado a la operación en tiempo real.




Fig. 8 - Comparación de los días sábado 17/03, domingo 18/03 y lunes 19/03/07, módulo de programación.




Fig. 8a - Comparación de los días sábado 17/03, domingo 18/03 y lunes 19/03/07, modulo destinado a la operación en tiempo real.




Fig. 9 - Comparación del día martes 20/03/07 módulo de programación.




Fig. 9a - Comparación del día martes 20/03/07 módulo destinado a la operación en tiempo real.

Se puede verificar que el desempeño de los modelos de red MLP-BP, ajustado y destinado su uso para la programación como para la operación en tiempo real, ha mostrado mejores resultados que aquellos obtenidos por la metodología actual.

6. Conclusiones

En este trabajo se presenta un modelo de previsión del suministro de energía eléctrica (MWh/h), de la Central Hidroeléctrica de Itaipu al sistema eléctrico paraguayo. El modelo utiliza redes neuronales artificiales que tiene como datos de entrada informaciones relacionadas al mes, día de la semana, hora, histórico del suministro energético y temperatura.

Los resultados muestran que el desempeño de los modelos de red MLP-BP, ajustados y

destinados su uso para la programación como para la operación en tiempo real, han mostrado mejores resultados que aquellos obtenidos por la metodología actual. A pesar de que el trabajo de aplicación de RNA para resolver el problema es inicial, los resultados son animadores, tomando en consideración que hay por explorar aún.

7. Reconocimientos

Este trabajo tuvo el soporte financiero de la Itaipú Binacional. Los autores agradecen la colaboración de la Dirección Técnica, Superintendencia de Operación, División de la Operación de Sistemas y División de Hidrología y Estudios Energéticos de la Itaipu Binacional por proveer los datos requeridos para la concreción del trabajo.

8. Referencias

- [1] A. Arce; T. Ohishi; S. Soares; Optimal Dispatch of Generating units of the Itaipú Hydroelectric Plant, IEEE Transactions on Power Systems, vol. 17, n° 1, pp. 154-157, February, 2002.
- [2] Wagner da S. Lima, Takaaki Ohishi. Uso de Variáveis Climáticas em Previsão de Carga no Período de Demanda de Ponta Utilizando Redes Neurais Artificiais, XIV SNPTEE – Seminario Nacional de Produção e Transmissão de Energia Elétrica, Belém, Pará, Brasil, 1997.
- [3] K. Y. Lee; J. H. Park; Short-Term Load Forecasting Using Na Artificial Neural Network, IEEE Transactions on Power Systems, Vol. 7, N° 1, February 1992.
- [4] D. C. Park; El-Sharkawi; R. J. Marks II; L. E. Atlas and M. J. Damborg; Electrical Load Forecasting Using An Artificial Neural Network, IEEE Transactions on Power Systems, Vol. 6, N° 2, May 1991.
- [5] Bonifacio Martín del Brío, Alfredo Sanz Molina, Redes Neuronales y Sistemas Difusos, Segunda Edición ampliada y revisada, Universidad de Zaragoza, Alfaomega Grupo Editor, Colombia, abril 2005.