

APLICACIONES DE INTELIGENCIA ARTIFICIAL (ANFIS) EN SISTEMAS DE SUMINISTRO DE ENERGÍA ELÉCTRICA: PRONÓSTICO DE DEMANDA DE MUY CORTO PLAZO Y PRONÓSTICO DE LOS PRECIOS SPOT DE CORTO PLAZO

Víctor Hugo Hinojosa
Investigación y Desarrollo

RESUMEN

En este trabajo se muestra dos posibles aplicaciones de la Inteligencia Artificial (IA), en base a un modelo neuro – fuzzy (ANFIS), a los Sistemas de Suministro de Energía Eléctrica (SSEE). Se utiliza IA debido a las ventajas de modelación, en lo que respecta con sistemas multivariable, y tiempo de cálculo. El modelo ANFIS aprende las relaciones pasadas, actuales y futuras de la demanda y los precios.

Se analiza además el performance del Modelo ANFIS comparado con una Metodología de referencia (ARIMA).

PALABRAS CLAVE: Pronóstico, Series de Tiempo, Inteligencia Artificial, Correlación, Sistema de Inferencia Fuzzy, Sobreentrenamiento.

1. INTRODUCCIÓN

• Parte I: Pronóstico de Demanda

El Pronóstico de Demanda es una tarea de singular importancia en la Planificación, Análisis y Operación de Sistemas de Suministro de Energía Eléctrica. Los Errores asociados al pronóstico pueden involucrar cuantiosas pérdidas a los Agentes del Mercado Eléctrico.

En efecto, el pronóstico de demanda es fundamental para:

- 1) Calcular los balances eléctricos y energéticos.
- 2) Planificar la programación y ejecución de la operación.
- 3) Elaborar los planes de expansión, inversiones y reemplazos.
- 4) Estimar las transacciones de compra y venta de energía y servicios.
- 5) Presupuestar los ingresos y egresos por dichas transacciones.
- 6) Calcular el margen de pérdidas y ganancias esperado por el agente.

Por todo esto, es muy importante que el pronóstico de demanda minimice todas las incertidumbres, considerando los cambios estructurales que se

están presentando en los Mercados Eléctricos y la introducción de competencia entre actores como resultado de la desregulación normativa, donde entran en juego intereses económicos que pueden ser afectados por la ineficiencia del pronóstico. Por lo tanto, los Agentes y los operadores del sistema deben trabajar con el mayor nivel de eficiencia.

El enfoque en el cual nos enmarcamos es la Programación de la Operación de muy corto plazo, un esquema se presenta en la Figura 1.

<p>Programación de la Operación de Muy Corto Plazo</p> <p>DATOS:</p> <ul style="list-style-type: none">- demanda cada 15 o 60 minutos- contratos de compra de energía- predespacho del parque generador- red de transporte detallada <p>PERIODO ANALIZADO: rango de horas a 1 día</p> <p>INTERVALO DE CÁLCULO: de 15 a 60 minutos</p> <p>RESULTADOS:</p> <ul style="list-style-type: none">- despacho del parque generador- control de tensión y reactivo- precios de mercado

FIGURA 1: Operación de Muy Corto Plazo

Entonces, la programación de muy corto plazo tiene por objetivo calcular la reprogramación del parque hidrotérmico, con la consideración específica del control de tensiones y despacho de potencia reactiva. Se deben satisfacer además, las restricciones vinculadas al parque de generación y a la red de transporte. La solución del problema planteado, establece el vínculo entre la programación de la operación de corto plazo (semanal) y la real del parque de generación, tanto en lo correspondiente a su potencia activa como reactiva.

Por lo tanto, es de suma importancia para esta reprogramación el pronóstico de demanda de muy corto plazo (PDMCP).

• Parte II: Pronóstico de Precios Spot

En el último tiempo, la tendencia en los mercados eléctricos apunta hacia modelos cada vez más liberalizados, en donde el precio de las transacciones de electricidad sea despejado por un algoritmo simple de mercado, en lugar de los complejos métodos centralizados basados en la solución de problemas de programación no lineal. El principal producto

que es comercializado en los mercados eléctricos es la Energía, pero puede coexistir otros mercados de servicios auxiliares, estos mercados normalmente están organizados en Pools y son administrados por un Operador Independiente del Sistema.

En el Mercado Eléctrico Mayorista (MEM) ecuatoriano existen dos mercados: el mercado spot y el mercado a término (contratos bilaterales), en el cual los contratos son pactados libremente.

Los precios del mercado spot son despejados por el Centro Nacional de Control de Energía - CENACE.

El pronóstico de los precios spot es una actividad importante para todos los participantes del mercado, ya que en base a estos se puede determinar el comportamiento futuro de los precios spot del mercado eléctrico, sin la necesidad de modelar a todos los participantes que interactúan y al sistema eléctrico de potencia.

Estos pronósticos sirven para los Agentes del mercado que requieren por ejemplo ofertas de compra/venta de energía, unidades de generación que requieren salir a mantenimiento, manejo de riesgo, entre otras. Entonces los Agentes del mercado requieren pronósticos confiables para que los productores maximicen su beneficio y los consumidores maximicen sus utilidades.

La organización del trabajo se presenta de la siguiente manera: en el segundo numeral se muestra el Estado del Arte en lo que respecta al pronóstico de demanda y precios, en el tercer numeral se discute la descripción del problema, en el cuarto numeral se presenta la teoría del Modelo ANFIS y se describe la posible red para la solución. Las pruebas, los resultados y las distintas comparaciones matemáticas se dan en el quinto numeral y las conclusiones del trabajo son enunciadas en el último numeral.

2. MARCO TEÓRICO DE REFERENCIA

El presente trabajo pretende contribuir con desarrollos metodológicos, modelos y propuestas para la aplicación de la Inteligencia Artificial en Mercados Eléctricos.

2.1. Pronóstico de Demanda de Muy Corto Plazo

El PDCMP es resultado de la combinación de datos históricos de demanda, variables externas climáticas (observadas o pronosticadas) y condiciones esperadas del sistema.

Su horizonte es de una a varias horas en adelante, posibilitando tomar medidas correctivas en la planificación diaria de la operación del sistema eléctrico.

• Factores que Afectan la Demanda Eléctrica

La demanda se ve influenciada por factores controlables (límites y parámetros del sistema y la tarifa como elemento regulador) y factores no controlables (costumbres de los consumidores, estructura económica, condiciones climáticas y factores aislados).

En el corto y muy corto plazos las condiciones climáticas (temperatura, humedad, velocidad del viento, visibilidad, etc.) son causas directas de la variabilidad del consumo de energía.

• Clasificación de los Métodos

En la referencia [17], se ha hecho una revisión bibliográfica de los Métodos aplicados al pronóstico de demanda: Estadísticos, Sistemas Inteligentes, Redes Neuronales Artificiales (ANN), Lógica Fuzzy y Métodos Híbridos.

En las referencias [24, 27, 26 y 11], se muestran algunos de los últimos aportes hechos en el Estado del Arte. Desde la aparición del Modelo ANFIS, ninguna investigación ha incursionado en la aplicación de esta metodología al PDMCP.

2.2. Pronóstico Diario de Precios Spot

El pronóstico de precios spot diario (PPSD) es una ardua tarea debido a que la serie histórica de precios no es estacionaria en media y varianza.

• Factores que Afectan el Precio Spot

Los precios spot se ven influenciados por variables explicativas tales como la demanda, energía disponible hidráulica, mantenimiento e indisponibilidades, precios de combustibles, entre las más importantes, las cuales ayudan a mejorar las predicciones.

• Clasificación de los Métodos

Para el pronóstico de precios spot en el estado del arte se han utilizado múltiples metodologías: Modelos ARIMA [7 y 9], modelos de regresión dinámico [20], otras técnicas de series temporales [21 y 8], redes neuronales artificiales [22], modelos de transformada wavelet [30 y 16], modelos heurísticos [15], técnicas Bayesianas [19], Modelos de Simulación [5, 1 y 4]

y Modelos híbridos [6]. Existe una sola publicación utilizando redes neuronales fuzzy [23].

Los precios en los mercados eléctricos han sido representados también como un proceso estocástico denominado Browniano [1].

Aplicaciones en otras Áreas de Investigación muestran que los resultados, utilizando el Método ANFIS, son muy promisorios y confiables, teniendo como ventajas, comparadas con otros métodos de pronóstico, las siguientes:

- Sobre los Métodos Estadísticos, la habilidad de modelar un complejo sistema multivariable sin ninguna formulación matemática compleja entre las variables de entrada.
- Sobre las Redes Neuronales Artificiales, el manejo de las incertidumbres de las variables de entrada y el aumento drástico de la velocidad de optimización mediante el proceso de fuzzificación.

3. DESCRIPCIÓN DEL PROBLEMA

Como sistema de prueba se utiliza el SSEE del Ecuador, el cual tiene una demanda máxima de 1 805 MW y una demanda mínima de 688 MW (año 2000).

Éste es dividido en 2 zonas: Costa y Sierra y cada zona tiene su temperatura de referencia (Guayaquil y Quito, respectivamente).

En este sistema se registran los valores de demanda horarios, incluyéndose el dato de las 19:30, ya que a esta hora aproximadamente se produce el pico máximo de demanda, por lo tanto para el PDCP se consideran 25 períodos (23 horarios y 2 de media hora).

Para el PDCMP se analizará el período desde el 05 de junio hasta el 17 de septiembre de 2000. Para este rango de análisis se cuenta con las series históricas de demanda (D) y temperatura de Quito y Guayaquil. En esta investigación se incluye solo la temperatura de Guayaquil (T), ya que se ha comprobado tiene una correlación mayor a 0,5 con la demanda [11]. En la Figura 2 se muestra las gráficas del período comprendido entre el 10 de junio y el 07 de julio de 2000.

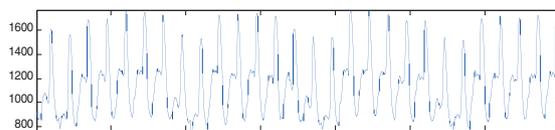


FIGURA 2: Demanda y Temperatura en el SSEE del Ecuador

Para el PPSD se cuenta con las series temporales de los precios diarios spot (P), demanda (D), precios de combustible del diesel (E) y fuel oil (F), capacidad disponible (G), energía disponible en Paute (B), nivel de Paute (A) y caudal de Paute (C) para el período comprendido entre julio de 2000 hasta abril de 2004.

En la Tabla 1 se realiza un análisis de correlación del precio spot con algunas variables explicativas y se cuantifica dicha correlación a través de la correlación de Pearson.

TABLA 1: Análisis de Correlación de Pearson

Pearson	A	B	C	D	E	F	G
Precio	-0,63	-0,65	-0,48	0,20	0,16	0,03	0,08

Con este análisis se determina que las variables que se correlacionan con el precio spot son: la energía disponible en Paute, el nivel y el Caudal de Paute. Aunque en el estado del arte se demuestra la correlación que tiene el precio con la demanda, cuando se analiza las variables diarias esta correlación desaparece. Además es importante notar que los precios de combustibles no tienen ninguna correlación con el precio spot diario.

3.1. Análisis de Datos Atípicos

Para las series temporales de demanda y temperatura se asume una distribución de datos normal $N(\mu, \sigma)$ y se considera que son datos atípicos los que se encuentran fuera del intervalo dado por $[\mu - 3\sigma, \mu + 3\sigma]$. Se elimina los días feriados (10 de agosto, 9 y 12 de octubre) y atípicos. Se reemplaza estos datos por sus correspondientes valores medios.

Para las series históricas utilizadas en el PPSD se considera que no se tiene datos atípicos y que los precios picos se considera como valores normales. En la Figura 3 se muestra la serie histórica del precio spot desde el 01 de julio de 2000 hasta el 31 de octubre de 2003.

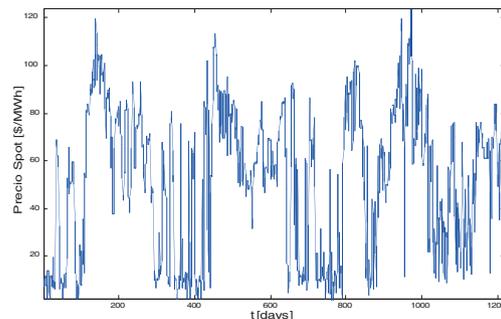


FIGURA 3: Precios Spot en el SSEE del Ecuador

3.2. Análisis de Series de Tiempo [3, 18 y 11]

Para el PDMCP el análisis se lo hace para 3 días (72 retardos: analizamos la estacionalidad diaria de la demanda), mediante la función de autocorrelación (ACF) de la demanda y la función de autocorrelación parcial (PACF) de la demanda (ver Figura 4). Para nuestra investigación se desprecia la estacionalidad semanal de la demanda.

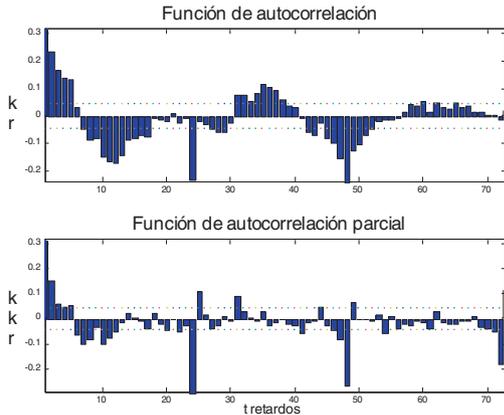


FIGURA 4: Análisis de Series de Tiempo para el PD MCP

La ACF de la demanda muestra la existencia de un patrón en la serie histórica y la PACF, verifica la existencia de procesos autoregresivos (AR) de orden: 1, 2, 24 y 48.

El resumen, de las variables explicativas y variable explicada se muestra en la Tabla 2.

TABLA 2: Variables Utilizadas en el PDMCP

PDMCP	Descripción	Orden del Proceso AR
Variable Explicativa	Demanda Temperatura	$D_{(t-1)}$, $D_{(t-2)}$, $D_{(t-24)}$, $D_{(t-48)}$, $D_{(t-72)}$ $T_{(t)}$
Variable Explicada	Demanda	$D_{(t)}$

Para el PPSD el análisis se lo hace para 2 meses (60 retardos), mediante la función de autocorrelación (ACF) de los precios spot y la función de autocorrelación parcial (PACF) de los precios spot (ver Figura 5).

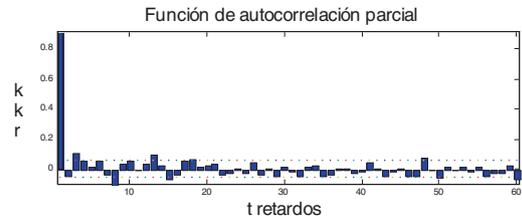
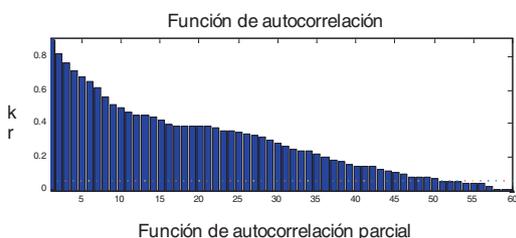


FIGURA 5: Análisis de Series de Tiempo para el PPSD

La ACF de los precios spot muestra la existencia de un patrón en la serie histórica y la PACF, verifica la existencia de procesos autoregresivos (AR) de orden:

1. Se desprecia los demás procesos debido a que se encuentran entre las bandas de confianza ($\sqrt{2/n}$), donde n es la longitud de la muestra.

El resumen, de las variables explicativas y variable explicada se muestra en la Tabla 3.

TABLA 3: Variables utilizadas en el PPSD

PPSD	Descripción	Orden del Proceso AR
Variable Explicativa	precio energía disponible nivel caudal	$P_{(t-1)}$ $B_{(t)}$ $A_{(t)}$ $C_{(t)}$
Variable Explicada	precio	$P_{(t)}$

4. ANFIS: ADAPTIVE NEURO-FUZZY INFERENCE SYSTEM

En el estado del arte de la Inteligencia Artificial se menciona que los sistemas híbridos que combinan lógica fuzzy, redes neuronales, algoritmos genéticos y sistemas expertos proporcionan los métodos más eficientes para resolver una gran variedad de problemas. Cada una de esas técnicas tiene propiedades computacionales particulares que las hace óptimas para resolver ciertos problemas. Uno de estos sistemas híbridos corresponde a los sistemas Neuro-Fuzzy, que combinan las técnicas de redes neuronales artificiales y las técnicas de inferencia fuzzy.

La lógica fuzzy proporciona un mecanismo de inferencia sobre la incertidumbre y las redes neuronales ofrecen grandes ventajas computacionales, tales como el aprendizaje, adaptación, tolerancia a fallas, el paralelismo y la generalización. Las redes neuronales son usadas para representar los sistemas de inferencia

fuzzy, los mismos que son empleados como sistemas de toma de decisiones. A pesar de que la lógica fuzzy puede codificar el conocimiento a través de etiquetas lingüísticas, usualmente toma mucho tiempo definir y ajustar las funciones de pertenencia.

Las técnicas de aprendizaje de las redes neuronales pueden automatizar este proceso y reducir sustancialmente el tiempo y el costo de desarrollo al mejorar el desempeño del modelo.

Teóricamente las redes neuronales y los sistemas fuzzy son equivalentes, pero en la práctica cada uno tiene sus propias ventajas y desventajas. En las redes neuronales, el conocimiento se adquiere automáticamente por el algoritmo de backpropagation, pero el proceso de aprendizaje es relativamente lento (gran cantidad de épocas de entrenamiento) y el análisis de la red entrenada es difícil (modelo de caja negra). No es posible extraer el conocimiento estructural (reglas) de la red neuronal ni puede éste integrarse a la información especial sobre el problema en la red neuronal con el fin de simplificar el procedimiento de aprendizaje. Los sistemas fuzzy son más favorables porque su comportamiento puede ser explicado con base en reglas fuzzy y, de esta forma, su desempeño puede ser ajustado modificando estas reglas. Sin embargo, la adquisición del conocimiento es difícil, y, además, el universo de discurso de cada variable necesita ser dividido en intervalos, por lo que las aplicaciones de los sistemas fuzzy se restringen a problemas en los cuales el conocimiento está disponible en un número de variables de entrada pequeño. Para superar el problema de la adquisición del conocimiento, las redes neuronales son extendidas para extraer automáticamente la reglas fuzzy de los datos numéricos.

4.1. Arquitectura del Modelo ANFIS

El modelo ANFIS fue propuesto por Jang [12], consiste de un sistema híbrido Neuro-Fuzzy, el mismo que es funcionalmente equivalente al mecanismo de inferencia Takagi-Sugeno (T-S) [25]. Para un sistema de inferencia T-S de primer orden, un conjunto de reglas fuzzy SI-ENTONCES es el siguiente (1).

- Regla 1: Si x es A1 & y es B1, entonces z1 = p1 x + q1 y + r1 (1)
- Regla 2: Si x es A2 & y es B2, entonces z2 = p2 x + q2 y + r2

Donde Ai y Bi son conjuntos fuzzy. La Figura 6 presenta este mecanismo de inferencia.

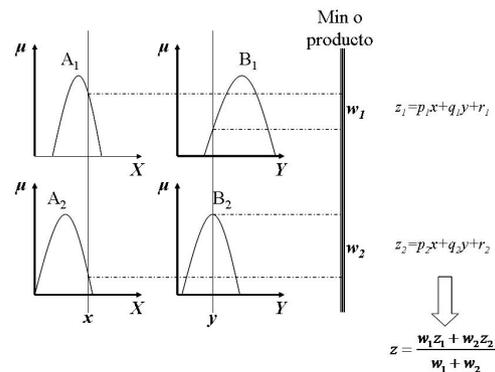


FIGURA 6: Sistema de Inferencia T-S de Primer Orden

Los niveles de activación de las reglas se calculan como $w_i = A_i(x) \wedge B_i(x)$ para $i=1,2$; donde, el operador lógico and (\wedge) puede ser modelado por una t-norma continua (producto). Las salidas individuales de cada regla son obtenidas como una combinación lineal entre los parámetros del antecedente de cada regla: $z_i = p_i x + q_i y + r_i$ para $i=1,2$. La salida de control del modelo z se obtiene por la normalización de los grados de activación de las reglas por la salida individual de cada regla, como se muestra en (2).

$$z = \bar{w}_1 z_1 + \bar{w}_2 z_2 \quad (2)$$

Donde, \bar{w}_1 y \bar{w}_2 son valores normalizados.

La red neuronal híbrida que representa este tipo de inferencia es una red adaptable con 5 capas [13], donde cada capa representa una operación del mecanismo de inferencia fuzzy. Esta red se muestra en la Figura 7.

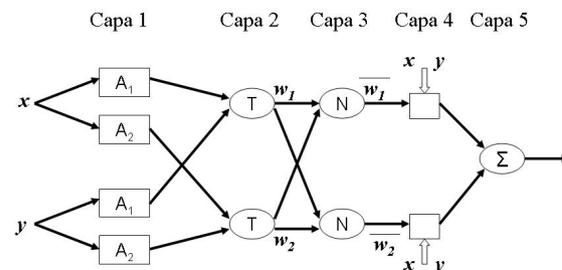


FIGURA 7: Arquitectura ANFIS para Inferencia T-S de Primer Orden

En esta arquitectura, todos los nodos de una misma capa tienen la misma función (los nodos representados con cuadros son nodos adaptables, es decir, sus parámetros son ajustables).

Capa 1: Las entradas en esta capa corresponden a las entradas x y y , y la salida del nodo es el grado de pertenencia para el cual la variable de entrada satisface el término lingüístico asociado a este nodo.

Capa 2: Cada nodo calcula el grado de activación de la regla asociada a dicho nodo. Ambos nodos están representados con una T, por el hecho de que ellos pueden representar cualquier t-norma para modelar la operación lógica "and". Los nodos de esta capa son conocidos como nodos de reglas.

Capa 3: Cada nodo en esta capa está representado por una N, para indicar la normalización de los grados de activación. La salida del nodo es el grado de activación normalizado (con respecto a la suma de los grados de activación) de la regla i .

Capa 4: La salida de los nodos corresponde al producto entre el grado de activación normalizado por la salida individual de cada regla.

Capa 5: El único nodo de esta capa calcula la salida total del sistema (agregación) como la suma de todas las entradas individuales de este nodo.

4.2. Aprendizaje con el Modelo ANFIS

El modelo ANFIS tiene dos conjuntos de parámetros que deben ser entrenados: los parámetros del antecedente (constantes que caracterizan las funciones de pertenencia) y los parámetros del consecuente (parámetros lineales de la salida del modelo de inferencia). El paradigma de aprendizaje del modelo ANFIS emplea algoritmos de gradiente descendente para optimizar los parámetros del antecedente y el algoritmo de mínimos cuadrados para determinar los parámetros lineales del consecuente. Debido a esta combinación se lo conoce como regla de aprendizaje híbrido.

Jang, describe que para aplicar el aprendizaje híbrido en grupo, en cada época de entrenamiento debe ejecutarse un paso *forward* y un paso *backward*. En el paso *forward*, los parámetros de las funciones de pertenencia son inicializados y se presenta un vector de entrada-salida, se calculan las salidas del nodo para cada capa de la red y entonces los parámetros del consecuente son calculados usando el método de mínimos cuadrados. Una vez identificados los parámetros del consecuente, el error es calculado

como la diferencia entre la salida de la red y la salida deseada presentada en los pares de entrenamiento. Una de las medidas más usadas para el error de entrenamiento es la suma de errores cuadráticos (3).

$$SEC = \sum_{k=1}^N (d_k - z_k)^2 \quad (3)$$

Donde:

d_k = Corresponden a los patrones de entrenamiento proporcionados (salidas deseadas).

z_k = Es la correspondiente salida de la red.

En el paso *backward*, las señales de error son propagadas desde la salida, en dirección de las entradas; el vector gradiente es acumulado para cada dato de entrenamiento. Al final del paso *backward* para todos los datos de entrenamiento, los parámetros de la capa 1 (parámetros de las funciones de pertenencia) son actualizados por el método descendente en una magnitud $\Delta\beta$ (4).

$$\Delta\beta = -\eta \frac{\partial E}{\partial \alpha} \quad (4)$$

Donde, η es la tasa de aprendizaje, que puede ser expresada como se modela en (5).

$$\eta = \frac{\rho}{\sqrt{\sum_{\alpha} \left(\frac{\partial E}{\partial \alpha} \right)^2}} \quad (5)$$

Donde, ρ es el tamaño del paso, i.e., la longitud de cada transición a lo largo de la dirección del gradiente en el espacio de parámetros. Esto significa que la tasa de aprendizaje es variable y se ajusta automáticamente. Un criterio heurístico para modificar el paso ρ puede ser encontrada en [14].

4.3. Armado de las T-uplas de Entrada – Salida

Para el PDMCP se incluye algunas variables explicativas encontradas en el Estado del Arte [11], como son: día, tipo de día, tipo de día similar. Las cuales ayudan a explicar de una mejor manera la varianza del pronóstico.

- El número de entradas al modelo ANFIS para el PDMCP será igual a 8.
- Para el PPSD el número de entradas será de 4.

4.4. Armado de Conjuntos de Entrenamiento, Validación y Test

Una red se considera que esta entrenada con éxito si puede aproximar los valores de los patrones de entrenamiento y puede dar interpolaciones suaves para el espacio de datos no entrenado (conjunto de validación).

Para la selección de los conjuntos de entrenamiento, validación y test, debe ser de tal manera que el conjunto de entrenamiento como el de validación contenga cada uno al menos 2/5 del total de duplas representativas. El conjunto de test es aconsejable contenga por lo menos 1/5 del total de duplas, para asegurar la capacidad predictiva de los ejemplos abarcados por los datos observados.

5. RESULTADOS DE LAS SIMULACIONES

Se utiliza para simular el Modelo ANFIS planteado el software MatLab 6,5 instalado en una PC con un procesador de 1,85 GHz y 1024 MB en RAM.

Se utiliza para el entrenamiento 500 ciclos (épocas).

Como criterio de parada del entrenamiento se utiliza la curva del error del conjunto de validación la cual llega a un mínimo (aunque el error de entrenamiento siga disminuyendo), con este criterio se asegura la convergencia de la red y la alta capacidad de generalización.

Este criterio permite eliminar el sobreentrenamiento (overfitting), debido a que el algoritmo backpropagation, tanto para las redes neuronales como para el Modelo ANFIS, es susceptible de este fenómeno.

Se utiliza el error relativo porcentual definido en (9), para comparar el performance de las distintas configuraciones.

$$Error = \frac{|x_{real} - x_{pronosticada}|}{x_{real}} * 100 \quad (9)$$

Donde, x representa el valor de demanda horario o el precio spot diario.

• Parte I: Pronóstico de Demanda

El tiempo de simulación para el PDMCP para 1 hora en adelante fue de 2,36 h (20,23 min en promedio diario).

El error promedio mínimo para la semana del 11 al 17 de septiembre de 2000 fue de 1,1265%. En la Figura 8 se muestra la demanda real y el PDCP para octubre,

se incluye los errores de pronóstico.

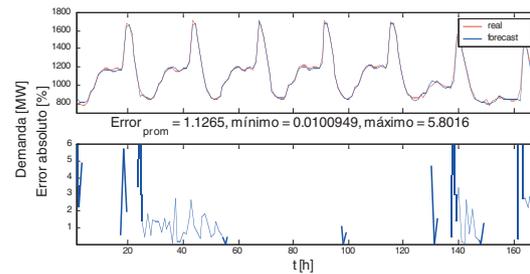


FIGURA 8: PDMCP para el SSEE del Ecuador

• Parte II: Pronóstico de Precios

El tiempo de simulación para el PPSD para 1 día en adelante fue de 7,37 min. El error promedio mínimo para la el período desde el 31 de enero hasta el 30 de abril de 2004 fue de 17,08%. En la Figura 9 se muestra la los precios spot reales y el PPSD, se incluye los errores de pronóstico.

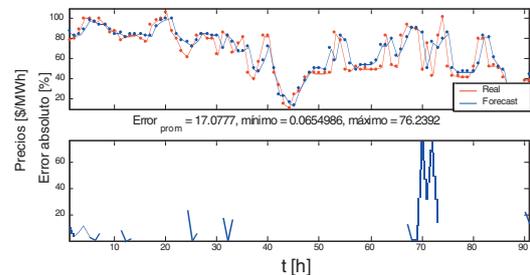


FIGURA 9: PPSD para el SSEE del Ecuador

5.1. Comparaciones Utilizando Diferentes Metodologías

Para poder compara al PDMCP y el PPSD se decide utilizar como Metodología de Referencia una aplicación realizada con Modelos Económicos (ARIMA), se utiliza el SPSS para efectuar dicha modelación.

• Parte I: Pronóstico de Demanda

En la Tabla 4 se resumen los errores relativos promedios del PDMCP para 1 hora en adelante.

TABLA 4: Errores del PDMCP para el SSEE del Ecuador

PDMCP	Error [%]	E_máx [%]
ARIMA(1,1,0),x(2,1,1) ₁₂	1,2215	8,9776
ANFIS	1,1265	5,8016

La mejor performance se obtiene con el Modelo ANFIS, con respecto a los otros métodos de pronóstico, reduciendo el error del PDMCP en un 7,78%, respecto a la Metodología de Referencia (ARIMA).

• **Parte I: Pronóstico de Precios**

En la Tabla 5 se resumen los errores relativos promedios del PPSD para 1 día en adelante.

TABLA 5: Errores del PPSD para el SSEE del Ecuador

PDMCP	Error [%]
ARIMA(1,0,0)	22,1735
ARIMA(2,1,9)	20,6501
ANFIS	17,0777

La mejor performance se obtiene con el Modelo ANFIS, reduciendo el error en un 17,30%, respecto a la Metodología de Referencia (ARIMA).

6. CONCLUSIONES

- Utilizando ANFIS logramos mejorar no solo el error promedio del PDMCP y del PPSD, sino también el error máximo.
- La incorporación de variables determinísticas como son día, tipo de día, etc., en el PDMCP ayuda a explicar de una mejor manera la varianza del pronóstico.
- Con la metodología ANFIS se puede plantear cualquier sistema multivariable como se hizo en el PPSD sin ningún problema. En cambio los modelos ARIMA son matemáticamente muy complejos de resolver con más de 2 variables explicativas.
- El análisis realizado para el PPSD mostró que el factor determinante para explicar la alta variabilidad de los precios son las variables relacionadas con el embalse Amaluz de la Central Paute.

7. BIBLIOGRAFÍA

[1] ANGELUS, A.; Electricity Price Forecasting in Deregulated Markets; Elect. J., Vol. 14, No. 3, pp. 32–41, 2001.

[2] ALLEN, E.; ILLIC, M.; Price – Based Commitment Decisions in the Electricity Market; Springer – Verlag, 1999.

[3] BOX, G. E.; JENKINS, G. M.; Time Series Analysis: Forecasting and Control; USA, Holden-Day Inc., 1976.

[4] BREIPOHL, A. M.; Electricity Price Forecasting Models; in Proc, IEEE Power Eng. Soc. Winter Meeting, Vol. 2, New York, 2002, pp. 963–966.

[5] BUNN, D. W.; Forecasting Loads and Prices in Competitive Power Markets; Proc. IEEE, Vol. 88, No. 2, pp. 163–169, Febrero 2000.

[6] CONEJO, A. J.; PLAZAS, M.; ESPÍNOLA, R.; MOLINA A.; Day – Ahead Electricity Price Forecasting Using the Wavelet Transform and ARIMA Models, IEEE Trans. Power Syst., Vol. 20, No. 2, pp. 1035–1042, Mayo 2005.

[7] CONTRERAS, J.; ESPÍNOLA, R.; NOGALES, F.; CONEJO, A. J.; ARIMA Models to Predict Next-Day Electricity Prices; IEEE Trans. Power Syst., Vol. 18, No. 3, pp. 1014-1020, Agosto 2003.

[8] CRESPO, J.; HLOUSKOVA, J.; KOSSMEIER, S.; OBERSTEINER, M.; Forecasting Electricity Spot Prices Using Linear Univariate Time Series Models; App. Energy, Vol. 77, No. 1, pp. 87–106, 2002.

[9] FOSSO, O. B.; GJELSVIK, A.; HAUGSTAD, A.; BIRGER, M.; WANGENSTEEN, I.; Generation Scheduling in a Deregulated System; IEEE Trans. Power Syst., Vol. 14, pp. 75–81, Febrero 1999.

[10] HAYKIN, S.; Neural Networks: A Comprehensive Foundation; USA, Prentice Hall, 1999.

[11] HINOJOSA, V. H.; Pronóstico de Demanda de Corto Plazo en Sistemas de Suministro de Energía Eléctrica Utilizando Redes Recurrentes (Jordan); Undécimo Encuentro Regional Iberoamericano de CIGRE (XI ERIAC), ciudad del Este – Paraguay, 2005.

[12] JANG, J-S. R.; Neuro-Fuzzy Modeling: Architecture, Analyses and Applications; PhD dissertation, Dept. Elect. Eng., California Univ., Berkeley, CA, 1992.

[13] JANG, J-S. R.; ANFIS: Adaptive-Network-Based Fuzzy Inference System; IEEE Tran. Systems, Man and Cibernetics, No. 23, pp. 665-685, 1996.

[14] JANG, J-S. R.; Input Selection for ANFIS Learning; Proceedings of the IEEE International Conference on Fuzzy Systems, New Orleans, 1996.

[15] JAU-JIA, G.; and LUH, P. B.; Market Clearing Price Prediction Using a Committee Machine With Adaptive Weighting Coefficients; in Proc. IEEE Power Eng. Soc. Winter Meeting, Vol. 1, pp. 77–82, New York 2002,

[16] KIM, C.-I.; YU I.-K.; SONG, Y. H.; Prediction of System Marginal Price of Electricity Using Wavelet Transform Analysis; Energy Convers. Manage, Vol. 43, pp. 1839–1851, 2002.

[17] LOTUFO, A. D.; MINUSSI, C. R.; Electric Power



- Systems Load Forecasting: A Survey; IEEE Power Tech Conference, Budapest-Hungria, 1998.
- [18] MAKRIDAKIS, S.; WHEELWRIGHT, S.; Forecasting: Methods and Applications; USA, John Wiley & Sons Inc., 1978.
- [19] NI, E.; LUH, P. B.; Forecasting Power Market Clearing Price and its Discrete PDF Using a Bayesian-based Classification Method; in Proc. IEEE Power Eng. Soc. Winter Meeting, Vol. 3, pp. 1518–1523, Columbus, OH, 2001.
- [20] NOGALES, F. J.; CONTRERAS, J.; CONEJO, A. J.; ESPÍNOLA, R.; Forecasting Next-day Electricity Prices by Time Series Models; IEEE Trans. Power Syst., Vol. 17, No. 2, pp. 342–348, Mayo 2002.
- [21] OBRADOVIC, Z.; TOMSOVIC, K.; Time Series Methods for Forecasting Electricity Market Pricing; in Proc. IEEE Power Eng. Soc. Summer Meeting, Vol. 2, pp. 1264–1265, Edmonton, AB, Canada, 1999.
- [22] RAMSAY, B.; WANG, A. J.; A Neural Network Based Estimator for Electricity Spot-pricing With Particular Reference to Weekend and Public Holidays; Neurocomput, Vol. 23, pp. 47–57, 1998.
- [23] RODRÍGUEZ, C. P.; y ANDERS, G. J.; Energy Price Forecasting in the Ontario Competitive Power System Market; IEEE Trans. Power Syst., Vol. 19, No. 1, pp. 366–374, Febrero 2004.
- [24] SRIVASTAVA, S. C.; VEANKATARAMAN, D.; Short-term Load Forecasting using Recurrent Neural Networks; Proceedings of the 4th International APSCOM – Hong Kong, pp. 145–150, Noviembre 1997.
- [25] TAKAGI, T.; SUGENO, M.; Fuzzy Identification of Systems and its Applications to Modeling and Control; IEEE Trans. Systems, Man and Cybernetics, No. 15, pp. 116–132, 1985.
- [26] TOPALLI, A. K.; ERKMEN, I.; A Hybrid Learning for Neural Network Applied to Short Term Load Forecasting; Neurocomputing 51, pp. 495–500, 2003.
- [27] VERMAAK, J.; BOTHA, E. C.; Recurrent Neural Network for Short-Term Load Forecasting; IEEE Trans. on Power Systems, pp. 126–132, Febrero 1998.
- [28] YAGER, R.; FILEV, D.; Generation of Fuzzy Rules by Mountain Clustering; J. of Intelligent and Fuzzy Systems, Vol.2, No. 3, pp. 267–278, 1994.
- [29] YANG, H. T.; HUANG, C. M.; A New Short Term Load Forecasting Using Self-Organizing Fuzzy ARMAX Models; IEEE Trans. on Power Systems, pp. 217–225, Febrero 1998.
- [30] YAO, S. J.; SONG, Y. H.; Prediction of System Marginal Prices by Wavelet Transform and Neural Network; Elect. Mach. Power Syst., Vol. 28, No. 10, pp. 983–993, 2000.



Víctor Hugo Hinojosa Mateus.-
Nació en Quito, Ecuador en 1975. Recibió su título de Ingeniero Eléctrico en la Escuela Politécnica Nacional en el 2000. Desde enero de 2000 hasta julio de 2001 se desempeñó como Ingeniero de Operación y Transmisión en el CENACE.

En el período de agosto de 2001 hasta julio de 2005 realizó estudios de doctorado en el Instituto de Energía Eléctrica de la Universidad Nacional de San Juan en la República Argentina. Actualmente, se desempeña como Investigador en el Área de Investigación y Desarrollo del CENACE y es Profesor en la Escuela Politécnica Nacional.

Sus áreas de interés están enmarcadas en la Operación y Planificación de Sistemas Eléctricos de Potencia utilizando Técnicas de Inteligencia Artificial.