

Víctor Hinojosa
Investigación y Desarrollo

Wladimir Llanos
ESPE

RESUMEN

En este trabajo se muestra el problema del Pronóstico de Demanda que es necesario para la Planificación de la Operación de corto plazo (horizonte semanal y diario) y muy corto plazo (horizonte diario) en los Sistemas de Suministro de Energía Eléctrica (SSEE).

Los modelos y algoritmos desarrollados consideran las incertidumbres asociadas, principalmente a variables climáticas como la temperatura, debido a la correlación que tiene en el corto plazo con la demanda de un Sistema Eléctrico.

Los principales puntos que se resuelven en este trabajo: 1. Consideración de un modelo de pronóstico no lineal, basado en Inteligencia Artificial, 2. Planteamiento de un Modelo Multivariable sin necesidad de complejas modelaciones, 3. Obtención de un Modelo Único de Pronóstico válido para distintos horizontes de pronóstico; y, 4. Determinación óptima de las entradas al Modelo de Pronóstico.

PALABRAS CLAVE: Pronóstico, Series de Tiempo, Correlación, Razonamiento Inductivo Fuzzy, Algoritmos Evolutivos.

1. INTRODUCCIÓN

El pronóstico de demanda hoy en día es una de las tareas más importantes en lo que respecta a responsabilidad y complejidad en Sistemas de Suministro de Energía Eléctrica (SSEE), ya que las sobrestimaciones de la demanda real ocasionan sobrecostos en el despacho económico y las subestimaciones provocan imprevisiones de la Reserva Rotante (Regulación Secundaria de Frecuencia) que pueden ocasionar problemas de estabilidad en el caso de contingencias.

El problema del Pronóstico de Demanda que es necesario para la Planificación de la Operación de mediano, corto y muy corto plazo se desarrolla en detalle en esta publicación.

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 tales razones, es muy importante que el pronóstico de demanda minimice todas las incertidumbres, considerando los dramáticos 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 que los Agentes y el propio Operador del Sistema deben trabajar con el mayor nivel de eficiencia posible.

La demanda eléctrica, al ser una función no lineal de las variables intervinientes, hace que el pronóstico de demanda sea básicamente un problema no lineal. En el corto plazo las condiciones meteorológicas (temperatura, velocidad del viento, humedad, etc.) causan variación en la demanda. Además se debe incluir otras variables exógenas como: tipo de día (laboral o fin de semana), estación del año, día feriado, hora etc., para disminuir la varianza del pronóstico, ya que la demanda presenta zonas de bajo consumo (poca actividad asociada a las horas: de la noche, de un día feriado o fines de semana), zonas de consumo muy pronunciado (zonas de mucha actividad simultánea de diferentes sectores) y zonas intermedias.

La organización de la publicación se presenta de la siguiente manera: en la segunda sección se muestra el Estado del Arte, en la tercera sección se discute la descripción del problema, en la cuarta sección se presenta el desarrollo de la plataforma gráfica. Los resultados y las distintas comparaciones matemáticas se dan en la quinta sección, el resumen final y las conclusiones del trabajo se enuncian en la sección sexta y en la última sección se detallan los respectivos agradecimientos.

2. MARCO TEÓRICO Y ESTADO DEL ARTE [4]

El razonamiento humano ha sido entendido como un proceso mental de simulación debido a que los humanos somos capaces de tomar decisiones aún sin tener el conocimiento total del fenómeno sólo reconociendo los patrones pudiendo así analizar el comportamiento del sistema.

2.1. Razonamiento Inductivo Fuzzy – FIR

La metodología Fuzzy Inference Reasoning (FIR) es una implementación de la metodología de análisis general de sistemas “General System Problem Solver (GSPS)”, que posibilita estudiar los modos conceptuales de comportamiento de sistemas dinámicos.

Fue reimplementada por F. Cellier de la Universidad de Arizona. Mediciones Fuzzy fueron añadidas a la metodología de modelación para tratar las incertidumbres de los límites, donde también se incluye el tratamiento de valores perdidos y las mediciones para estimar la predicción del error.

En la Figura 1 se muestran las cuatro etapas de la metodología.

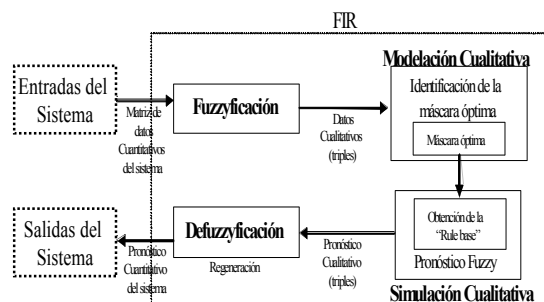


FIGURA 1: Razonamiento Inductivo Fuzzy

Es importante notar que el razonamiento propiamente dicho no involucra las etapas de fuzzyficación y defuzzyficación, pero son esenciales para que la metodología FIR opere en un entorno mixto (cualitativo/cuantitativo) de modelación y simulación.

Fuzzyficación (Fuzzy Recoding)

El objetivo de este proceso es aumentar drásticamente la velocidad de optimización. Si tenemos una relación entre n entradas y una salida, en lugar de realizar la búsqueda en el espacio continuo n -dimensional para encontrar el óptimo patrón de entrada/salida, la búsqueda es limitada al espacio discreto c -dimensional de los valores clase.

Este proceso convierte los datos cuantitativos que describen el comportamiento del sistema (series temporales: demanda y temperatura y variables auxiliares: tipo de día, etc.) a una trayectoria triple cualitativa.

El primer elemento de la variable triple se llama “valor clase” (class value) y representa una discretización gruesa de los valores originales de la variable.

El segundo elemento se llama “valor de membresía fuzzy” (fuzzy membership value) y denota el nivel de confianza expresado en el valor clase elegido para representar un particular valor cualitativo.

El tercer elemento se llama “valor del flanco” (side value), el cual indica si el valor cuantitativo está a la derecha o a la izquierda del valor pico de la función de membresía fuzzy asociada.

El valor del flanco que es particular de la metodología FIR (no es comúnmente utilizado en la lógica fuzzy), es responsable de preservar el completo conocimiento del valor original cuantitativo.

Modelación Cualitativa (Qualitative Modeling)

La modelación cualitativa tiene como objetivo identificar los patrones (espaciales y temporales) en el tiempo, mediante la determinación del grupo de variables de entrada que mejor explican el comportamiento entrada – salida. Tal relación es llamada máscara de correlación (mask).

En la metodología de pronóstico se utilizó para encontrar las entradas del modelo (máscara de correlación) los algoritmos evolutivos “Simulated Rebounding Algorithm”, como se detalla en el ítem 2.2.

Simulación Cualitativa (Qualitative Simulation)

El objetivo de esta etapa es analizar y aprender patrones observados en la máscara de correlación con el fin de predecir el comportamiento futuro en base a los datos históricos.

El pronóstico opera en dos etapas:

- 1) Etapa determinística: el patrón de entrada para el pronóstico es extraído de la matriz de valores clase por medio de la máscara y es comparado con todos los patrones análogos de la matriz de comportamiento del sistema (datos históricos). Para todos aquellos patrones que coinciden con el patrón de entrada, se observan los valores clase de salida.
- 2) Etapa estadística: se realiza la predicción del valor más probable de salida, a partir de las observaciones anteriores, mediante un promedio ponderado de los valores más próximos en la base de datos de entrenamiento. En esta etapa se utiliza la regla 4-NN (4 más cercanos vecinos).

Defuzzyficación (Regeneration)

En esta etapa las predicciones de los valores de membresía, funciones flanco y clase de la salida promedio son convertidas a predicciones cuantitativas usando la operación inversa a la fuzzyficación.

2.2. Algoritmos Evolutivos – SRA

Para encontrar las entradas al modelo de pronóstico se consideró la aplicación del algoritmo Simulated Rebounding Algorithm (SRA), que pertenece a la clase de algoritmos estocásticos (randomization algorithms) basados en búsqueda local aleatoria controlada (como lo es, entre otros, el Simulated Annealing). El SRA ha sido contrastado con el Simulated Annealing y algunas implementaciones de Algoritmos Genéticos en problemas de optimización con similares características y debido a la alta performance del mismo es que se eligió como motor de optimización del desarrollo aquí planteado.

La Simulación del Proceso Físico de Rebotes Simulados

Suponiendo que se lanza una pelota con coeficiente de elasticidad cercano a 1 sobre una superficie S , la pelota caerá sobre la superficie debido a la acción del campo gravitatorio en el cual esta inmersa. El choque producido por la caída podrá afectar a la energía cinética de la pelota si parte de esta energía es disipada en deformaciones permanentes (choque inelástico). Estas deformaciones serán proporcionales a la energía cinética del choque, siendo ésta la equivalente a la diferencia de energía potencial desde el punto de choque hasta la altura desde la cual cae la pelota. Si el proceso no es detenido, los rebotes se detendrán cuando la energía cinética de la pelota sea cero. En este proceso de

rebotes inelásticos, la pelota choca con distintos puntos de la superficie, desviada por los mismos rebotes sobre una superficie no plana. Si la superficie posee “valles” y “lomas”, los puntos pertenecientes a un valle tendrán menor energía potencial que las lomas. Por la acción de la gravedad, la pelota buscará detenerse sobre algún valle, y dependiendo de la energía cinética que posea, será capaz de saltar montes para explorar nuevos valles.

La analogía con un problema de optimización combinatorial se realiza haciendo una equivalencia entre la superficie de rebotes y el espacio de soluciones, y entre la altura de cada punto de la superficie y el valor de la función de costo correspondiente a esa solución. El SRA resulta así una extrapolación multidimensional del proceso físico de rebotes. Debido a la acción de la gravedad y a la pérdida gradual de energía cinética y potencial debido a las colisiones, al final del proceso de rebotes simulados, la pelota se detiene sobre el mínimo global (punto de menor altura de la superficie) o sobre algún mínimo local cercano al global. La Figura 2 muestra por simplicidad un ejemplo unidimensional: como se muestra con las líneas de trayectoria, la pelota puede alcanzar el mínimo global (escalón 11) si es lanzada desde el punto A ó C; sin embargo, es atrapada en el mínimo local del escalón 14 si la pelota es lanzada desde el punto B.

Es decir, el mínimo global es alcanzado si la energía potencial inicial (E_0), y el porcentaje de pérdida de energía debido a colisiones inelásticas (α) permiten saltar todos los mínimos locales durante el proceso de rebotes.




FIGURA 2: Ejemplo Unidimensional de Rebotes Simulados

En el SRA las deformaciones producidas por las colisiones pueden ser de tres tipos:

- a) **Deformación transitoria**, es decir, que la pelota no pierde energía cinética por ser la altura de la caída pequeña.
- b) **Deformación leve**, cuando la pelota rebota sobre las paredes de un valle por ser su energía

potencial menor que la altura del punto de destino, disminuyendo su energía potencial en un valor pequeño.

- c) **Deformación permanente**, cuando la pelota pierde energía cinética debido a una colisión provocada por una altura considerable de caída.

Estos tipos de deformación actúan en el proceso de optimización de diferente manera. La deformación transitoria es la que permite explorar el espacio de búsqueda. Si sólo existiera este tipo de deformaciones, el proceso no se detendría nunca, si no fuera por la pérdida de energía provocada por fricción y rozamiento. La deformación leve disminuye la energía de la pelota cuando es atrapada en un valle, y provoca la detención del proceso si no existe ninguna solución con energía potencial menor que la de la pelota (valle profundo). La deformación permanente acelera la convergencia hacia el óptimo, ya que disminuye la energía potencial de la pelota cuando ésta es muy superior a la de la superficie en el entorno de rebotes.

3. DESCRIPCIÓN DEL PROBLEMA

La demanda que se considera para el análisis es la generación bruta del SSEE del Ecuador. Además, se utiliza solamente la temperatura máxima de la Costa, debido a la correlación encontrada en investigaciones anteriores [4].

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 se consideran 25 períodos (23 horarios y 2 de media hora).

En la Tabla 1 se muestra la estructura del sistema multivariable para el pronóstico de demanda.

TABLA 1: Sistema Multivariable para el Pronóstico

TIPO DE DÍA	T_max costa	DEMANDA
day (t-n)	TM_Gye (t-n)	load (t-n)
day (t-n-1)	TM_Gye (t-n-1)	load (t-n-1)
...
day (t-1)	TM_Gye (t-1)	load (t-1)
day (t)	TM_Gye (t)	load (t)

El análisis que se va a mostrar en la siguiente sección corresponde al procedimiento del pronóstico semanal, pudiendo realizar actualizaciones diarias y horarias al pronóstico.

4. DESARROLLO DE LA PLATAFORMA GRÁFICA – MERLYN

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.

En la Figura 3 se muestra la pantalla principal de la aplicación desarrollada en Visual C.



FIGURA 3: Pantalla Principal de la Interfaz MERLYN

4.1. Cargar Datos de Demanda

Primeramente, se debe cargar el archivo (base de datos.xls) donde está la base de datos histórica de la demanda, este archivo cuenta con datos históricos desde el 01 de enero de 2006 hasta las 24:00 del sábado 18 de agosto de 2007. En la Figura 4 se muestra este procedimiento.

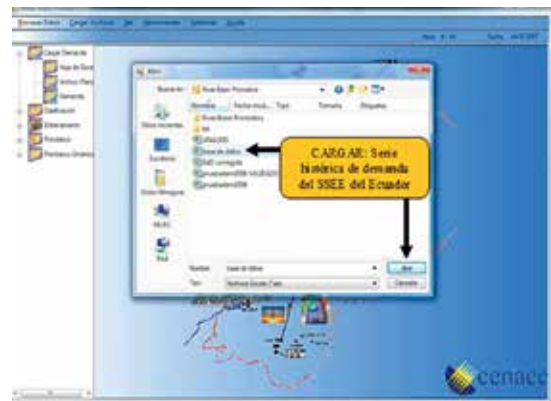


FIGURA 4: Pantalla para Cargar la Base de Datos

Ahora, se debe cargar el archivo plano (RGDSM19.09) el cual es generado por el Área Centro de Operaciones, este archivo contiene los datos de demanda real hasta

las 09:00 del domingo 19 de agosto. En la Figura 5 se muestra el procedimiento.



FIGURA 5: Pantalla para Cargar el Archivo Diario (Plano)

Finalmente, para terminar con el proceso de obtención de los datos de demanda, se ha desarrollado un algoritmo para validar los últimos datos reales de demanda (nueve horas del domingo 19 de agosto) – se supone que los datos de demanda están previamente validados hasta el día sábado 18 de agosto. Se muestra estos datos utilizando una tabla de Excel con su respectivo gráfico.

En la interfaz se muestran los datos reales del mismo día para las 3 semanas anteriores (12 de agosto, 05 de agosto y 29 de julio) y la respectiva media muestral de estos 3 días. En la Figura 6 se muestra el algoritmo de validación de la demanda.

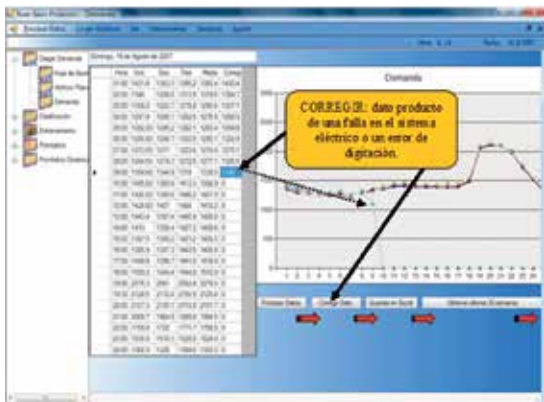


FIGURA 6: Algoritmo de Validación de Datos

El dato erróneo se lo corrige utilizando el valor medio de la demanda del mismo día de las 3 semanas anteriores (1 339,5 MW) ó en el caso de una desconexión se puede ingresar el valor desconectado de demanda. Una vez que se ha validado los nuevos datos se procede a guardar la nueva base de datos (tiene 9 datos reales más que la base de datos anterior).

Finalmente, se obtiene las últimas 20 semanas de datos reales (3 500 datos), en investigaciones anteriores se ha demostrado la eficiencia en tiempo y precisión de esta ventana dinámica.

4.2. Análisis de Clases para la Demanda

Para que el algoritmo de pronóstico, basado en la metodología FIR & SRA, pueda ejecutarse se necesita conocer los valores de demanda para cada período (pico, media, valle y resto).

Para estimar estos valores de demanda se utiliza un algoritmo de Clustering llamado Fuzzy C-Means [1], el cual ha obtenido resultados confiables y precisos.

Como resultados de esta etapa, se obtiene los valores reales de cada período de demanda, considerando que de lunes a viernes se tiene 4 clases (pico, media, valle y resto), el sábado se tiene 3 clases (pico, media y valle) y el domingo se tiene 2 clases (pico y valle).

En la Figura 7 se visualiza la aplicación del algoritmo, para las 20 semanas de datos consideradas anteriormente.

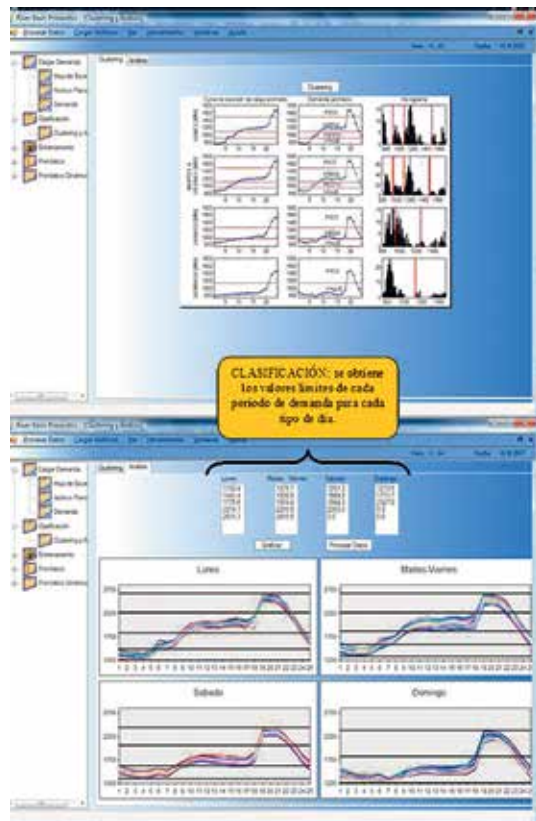


FIGURA 7: Análisis de los Periodos de Demanda

4.3. Algoritmo de Entrenamiento Supervisado Basado en el Algoritmo SRA

El método de entrenamiento que se propone aplicar es el “Aprendizaje Supervisado”, utilizando como valor de referencia los datos horarios de la demanda de la última semana de entrenamiento. Para encontrar las entradas del modelo de pronóstico, tal que esta configuración minimice la sumatoria de los errores obtenidos en la última semana de entrenamiento, se utiliza - para el cálculo del error - el pronóstico de demanda para 1 hora en adelante¹ y la demanda real histórica para dicha hora.

El análisis del espacio de soluciones se realiza mediante la minimización de la función de evaluación o “función objetivo”, que es igual al promedio de los últimos 175 errores relativos del pronóstico horario respecto del valor real histórico de la demanda para la semana de entrenamiento, según lo expresa la ecuación (1).

$$Error(v) = E_{(v)} = \frac{\sum_{i=1}^{175} \left(\frac{\hat{D}_{t-i} - D_{real,t-i}}{D_{real,t-i}} \right) * 100 [\%]}{175} \quad (1)$$

Donde:

\hat{D}_t = Es el pronóstico para la hora t .

$D_{real,t}$ = Es la demanda histórica real de la hora t durante la última semana de los datos de entrenamiento.

En la Figura 8 se muestra la ejecución del algoritmo de entrenamiento. Una vez que el entrenamiento terminó (8,82 min), se debe cargar las entradas óptimas del modelo de pronóstico que se obtuvieron.



FIGURA 8: Menú para Entrenamiento Supervisado

Este entrenamiento es repetido cada semana, ya que se considera que las entradas halladas por el algoritmo son válidas para 1 semana. Por lo tanto, el algoritmo nuevamente deberá ser repetido a las 09:00 del domingo 26 de agosto de 2007.

4.4. Pronóstico de Demanda Utilizando la Metodología FIR

i) La Dirección de Planeamiento del CENACE debe realizar la Programación de la Operación de Mediano y Corto plazo (de 24 horas hasta 168 horas en adelante), para lo cual requiere:

- Pronóstico de demanda con 1 semana de adelanto, es decir necesita el pronóstico de demanda con 168 horas de adelanto (mediano plazo); para la Programación Semanal.
- Pronóstico de demanda con 24 horas de adelanto: para la Programación Diaria.

En la Figura 9 se muestra el pronóstico semanal.

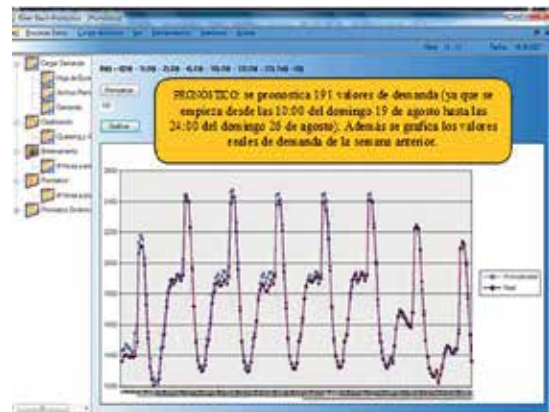


FIGURA 9: Menú para Pronóstico Semanal, Diario y Horario

El pronóstico de demanda se lo guarda también en un archivo de texto (stif_result.txt), con lo que la Dirección de Planeamiento podría utilizar estos datos para realizar la Programación Semanal.

Para el pronóstico diario (un día de adelanto), se utilizaría los 25 datos de demanda del lunes 20 de agosto (stif_result.txt), datos que servirán como entrada para el Despacho Económico.

El modelo desarrollado tiene la ventaja de incorporar los últimos datos reales del sistema para analizar

¹ “1 hora de adelanto” significa que se asumen conocidos todos los datos para las horas anteriores a la pronosticada. “1 día de adelanto” significa que se pronostican 24 horas para $t+i$ ($i=0,\dots,23$), considerando conocidos (reales)

todos los datos para las horas $t-j$ ($j>0$) y tomando los valores pronosticados ya calculados entre la hora t y $t+1$.

la nueva tendencia de la demanda con respecto al pronóstico semanal.

Para el pronóstico de demanda del martes, se debería incorporar los datos reales de demanda del domingo 19 y los 9 datos reales de demanda del lunes 20 de agosto).

En la Figura 10 se muestra el pronóstico de demanda para el martes 21 de agosto, no es necesario realizar el Clustering de la demanda, y con las mismas entradas obtenidas en el entrenamiento anterior (se considera que estas entradas son válidas para pronosticar desde las 10:00 del domingo 19 de agosto hasta las 23:00 del domingo 26 de agosto) se realiza el pronóstico.

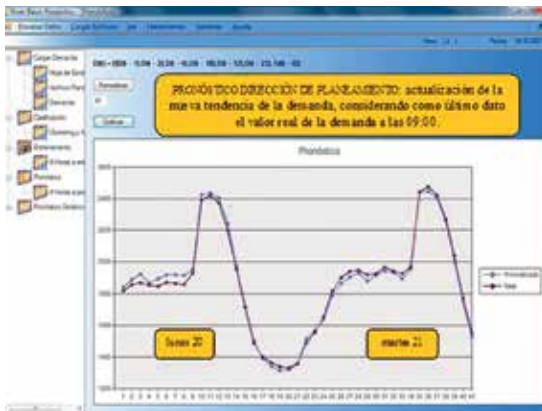


FIGURA 10: Aplicación al Pronóstico para 1 Día de Adelanto

ii) La Dirección de Operaciones del CENACE debe realizar la Programación de la Operación de Muy Corto Plazo (de 1 a 24 horas de adelanto), para lo cual requiere:

- Pronóstico de demanda desde 1 a varias horas en adelanto.

Los 16 datos de iniciales, correspondientes al domingo 19 de agosto (ver Figura 9) los podría utilizar el Área Centro de Operaciones. Datos que servirán para analizar la tendencia de demanda desde las 10:00 hasta las 24:00.

El modelo desarrollado tiene la ventaja de incorporar los últimos datos reales del sistema, por lo tanto, se podría incorporar los datos reales hora a hora y obtener una estimación de la curva de demanda hasta finalizar el día. En la Figura 11 se muestra el pronóstico de demanda cuando se ha cargado los valores reales de demanda del domingo 19 de agosto.

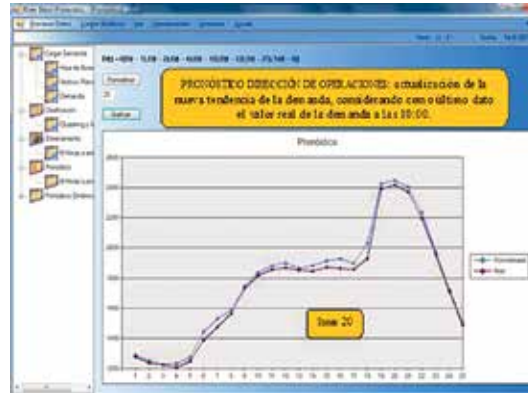


FIGURA 11: Aplicación al Pronóstico de Muy Corto Plazo

Para realizar este pronóstico hace falta solo cargar la base de datos (base de datos.xls y el RGDS19.09 → se debe proceder a validar los 16 valores de demanda de este archivo, correspondientes desde las 10:00 hasta las 24:00) y no es necesario realizar el Clustering de la demanda.

5. ANÁLISIS DE RESULTADOS

Se utiliza el error relativo porcentual definido en la ecuación (2), para comparar el performance del modelo de pronóstico.

$$Error = \frac{|x_{real} - x_{pronosticada}|}{x_{real}} * 100 \quad (2)$$

Donde:

x = Representa el valor de demanda horario.

En la Tabla 2 se detallan la media y la desviación estándar del error de test, considerando 3 semanas de test simuladas (del 11 al 24 de septiembre de 2000 y del 08 al 14 de mayo de 2006), resultantes de la aplicación de la Metodología FIR & SRA [4] y su comparación con los resultados obtenidos con el método ARIMA (CENACE), modelo Neuro – Fuzzy [2] y con las Redes Recurrentes de Jordan (RR) [3]. Se muestra además el error máximo obtenido en el pronóstico con cada uno de los Métodos de Pronóstico antes mencionados.

TABLA 2: Media, Desviación Estándar y Máximo Error Obtenido con Distintos Métodos de Pronóstico. Análisis de Errores Período 1

MÉTODO DE PRONÓSTICO	MEDIA	DESVIACIÓN	E_max
ARIMA	1,5873	1,2617	8,0298
RR - JORDAN	1,4729	1,2064	7,1311
ANFIS	1,4364	1,1817	6,992
FIR & SRA	1,1672	1,0633	6,3374

Se realizaron pruebas on-line del pronóstico entre los resultados obtenidos por la DPL con el método ARIMA y el pronóstico que obtuvo ID con la metodología FIR & SRA considerando como período de prueba desde el 02 de enero hasta el 24 de enero de 2007, en la Tabla 3 se detalla la media del error.

TABLA 3: Análisis de Errores Período 2

MÉTODO DE PRONÓSTICO	MEDIA
ARIMA	2,2
FIR & SRA	2,2

Por pedido de la DEJ considerando la importancia del mantenimiento de la fase AB de la Central Paute (5 x 105 MW), se realizó el pronóstico de demanda para la semana desde el 17 al 23 de febrero de 2007. En la Tabla 4 se detalla la media del error.

TABLA 4: Análisis de Errores Período 3

MÉTODO DE PRONÓSTICO	MEDIA
ARIMA	1,9545
FIR & SRA	1,4696

La mejor performance, con respecto al Pronóstico de Demanda para un día en adelante, se obtiene con la metodología FIR & SRA, con respecto a los otros métodos de pronóstico, reduciendo el error del pronóstico en un 17%, respecto a la Metodología de Referencia (ARIMA).

Se ha demostrado también que esta metodología tiene un excelente performance para el pronóstico de demanda de muy corto plazo (de 1 hasta 24 horas en adelante).

6. CONCLUSIONES

- Se ha resuelto el Pronóstico de Demanda con un horizonte de hasta 1 semana en adelante (para la Programación Semanal) incluyendo la actualización diaria mediante la incorporación de nueva información relacionada con las variables explicativas de "demanda" (para la Programación Diaria). El modelo planteado presenta la ventaja de utilizar información real del sistema eléctrico de los últimos períodos horarios de demanda y poder así estimar el comportamiento de la nueva tendencia de la demanda, disminuyendo así las desviaciones de la demanda real con respecto a la demanda pronosticada (subestimación o sobreestimación).

- Esta modelación Cualitativa – Cuantitativa posee la ventaja de poder incluir n variables explicativas, sin necesidad de una modelación compleja, debido a la formulación multivariable inherente al Razonamiento Inductivo Fuzzy.
- Frente a la limitación que presentan las metodologías tradicionalmente usadas en series de tiempo, las cuales encuentran mediante la función de autocorrelación parcial un grupo de entradas que son validas para un determinado período de tiempo (por ejemplo una estación del año), la nueva metodología aquí propuesta realiza un proceso dinámico de selección de entradas del modelo, que posibilita realizar un seguimiento a la tendencia de la demanda en forma instantánea.
- La intervención del Planificador u Operador es mínima, ya que los parámetros necesarios del modelo son intuitivos y optimizados por la misma metodología.
- Tanto los modelos como los algoritmos desarrollados han sido validados exhaustivamente con datos provenientes de la demanda real del SSEE del Ecuador.
- Este desarrollo poseen un potencial de aplicación que excede en gran medida el ámbito del Pronóstico de Demanda y son por tanto aplicables a otros problemas de la Planificación y Operación de sistemas de potencia como por ejemplo el Pronóstico de Caudales.

7. BIBLIOGRAFÍA

- [1] BEZDEK J. C.; Fuzzy Mathematics in Pattern Classification, Tesis doctoral, Centro de Matemáticas Aplicadas, Universidad de Cornell, 1973.
- [2] HINOJOSA V.; Pronóstico de Demanda de Corto Plazo en Sistemas de Suministro de Energía Eléctrica utilizando ANFIS, III Congreso Internacional de la Región Andina, Quito, 2007.
- [3] HINOJOSA V.; Pronóstico de Demanda de Corto Plazo en Sistemas de Suministro de Energía Eléctrica utilizando Redes Recurrentes (Jordan), XI ERIAC, Paraguay, 2005.
- [4] HINOJOSA V.; Pronóstico de Demanda de Corto Plazo en Sistemas de Suministro de Energía Eléctrica utilizando Inteligencia Artificial, Tesis de doctorado, Instituto de Energía Eléctrica de la Universidad Nacional de San Juan, Argentina, 2007.



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

En el período agosto 2001 a julio 2005 realizó estudios de doctorado en el Instituto de Energía Eléctrica de la Universidad Nacional de San Juan en la República Argentina, a través de una beca otorgada por el Servicio Alemán de Intercambio Académico (DAAD). Actualmente, se desempeña como Investigador en el Área de Investigación y Desarrollo del CENACE y es profesor en la EPN. Sus principales áreas de interés

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



Wladimir Llanos Tapia.- Nació en Cuenca, Ecuador en 1983. Es egresado de la Carrera de Ingeniería de Sistemas e Informática en la Escuela Politécnica del Ejército. Actualmente realiza su tesis de grado en el Área de Investigación y Desarrollo del CENACE.

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