

# PRONÓSTICO DE DEMANDA DE MUY CORTO PLAZO UTILIZANDO RAZONAMIENTO INDUCTIVO FUZZY Y ALGORITMOS EVOLUTIVOS

Víctor Hinojosa  
Investigación y Desarrollo

Lorena Herrera  
Dirección de Transacciones Comerciales

## RESUMEN

Este trabajo se enfocará en la modelación Cualitativa–Cuantitativa Razonamiento Inductivo Fuzzy (FIR), aplicada al problema de Pronóstico de Demanda de Muy Corto Plazo (PDMCP). El PDMCP predice el comportamiento de la demanda a partir del último dato real agregado, con el fin de establecer las desviaciones de la demanda programada versus la real.

La Metodología FIR & SRA propuesta se verifica con varios horizontes de pronóstico, verificando la eficiencia del modelo. El modelo considera la temperatura, debido a la correlación que tiene en el corto plazo con la demanda de un Sistema Eléctrico.

**PALABRAS CLAVE:** Series Temporales, Inteligencia Artificial, Razonamiento Inductivo Fuzzy, Algoritmos Evolutivos.

## 1. INTRODUCCIÓN

A mediados de los años 1970, el pronóstico de la demanda de energía eléctrica había recibido escasa atención de la opinión pública ya que el entorno económico anterior a la primera crisis de petróleo se podía considerar relativamente estable, el bajo precio de los combustibles utilizados en la generación de la energía eléctrica era bastante predecible, las tasas de interés eran moderadas y no existían demasiados problemas para que los mercados de capitales proporcionen los fondos necesarios para la expansión del sector eléctrico. Razón por la cual, se consideraba un proceso relativamente simple y constituía un reflejo directo de los requerimientos instantáneos de potencia por parte de los consumidores en base a datos históricos. En la actualidad es una de las tareas de mayor responsabilidad y complejidad, que tras de sí conlleva repercusiones importantes para los Operadores del sistema y Agentes del Mercado, cuando son de mala calidad.

Es así que bajo este contexto, es muy importante que el pronóstico de la 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.

## Programación en el Muy Corto Plazo

Tiene como objetivo la reprogramación del parque hidro - térmico, con las consideraciones específicas de control de tensiones y despacho de potencia reactiva. Además debe satisfacer, las restricciones vinculadas al parque de generación y a la red de transporte, para lograr la explotación óptima del sistema en:

- Gestión de arranques y paradas de los grupos térmicos.
- Gestión de bombeo diario.
- Programación horaria (asignación en tiempo real de grupos térmicos e hídricos).

El pronóstico de demanda, integrado con la información del Despacho Horario económico, generación disponible, costo de generación y requerimientos de reserva rodante impuestos por un operador independiente del sistema, son usados para determinar la mejor estrategia de utilización de los recursos hidro - térmicos.

## 2. MARCO TEÓRICO DE REFERENCIA

El presente trabajo pretende contribuir con desarrollos metodológicos, modelos y propuestas para la aplicación de la Inteligencia Artificial en el Pronóstico de la Demanda de muy Corto Plazo, para describir la conducta futura de la demanda eléctrica considerando sus rangos de horizonte, factores dominantes y comportamientos de los datos.

### 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 plazo las condiciones climáticas (temperatura, humedad, velocidad del viento, visibilidad, etc.) son causas directas de la variabilidad del consumo de energía.

### 2.1. Clasificación de los Métodos de Pronóstico

Los métodos para establecer el pronóstico de la demanda de energía eléctrica son numerosos, pero conceptualmente pueden agruparse en dos categorías: métodos cuantitativos y métodos cualitativos.

#### Métodos Cuantitativos

Se basa en la idea de que se pueden usar los datos relacionados con la demanda del pasado para realizar pronósticos. Y son aplicados bajo tres condiciones:

- Existe información histórica disponible.
- Esta información se puede cuantificar en forma de datos.
- Se puede asumir que el comportamiento histórico se repetirá en el futuro. Esta premisa sirve de base para muchos métodos sean cualitativos o cuantitativos.

#### Métodos Cualitativos

Son métodos subjetivos que se basan en estimaciones y opiniones. Razón por la cual, es difícil cuantificar la precisión del pronóstico; su aplicación es casi exclusiva para mediano y largo plazo.

En el Estado de Arte de los métodos de Pronóstico de Demanda en los SSEE se los divide en dos grupos los métodos estadísticos y las técnicas basadas en Inteligencia Artificial.

#### i) Métodos Estadísticos

Se basan en el análisis de series de tiempo y asumen que la demanda es una combinación lineal de variables independientes.

#### ii) Técnicas Basadas en la Inteligencia Artificial

Estos modelos poseen la habilidad de mejorar la precisión, ya que considera que la demanda es una función no lineal.

La ventaja es que no requiere ninguna formulación compleja o correlación cualitativa.

Éstos se dividen en:

- Sistemas expertos.
- Lógica difusa.
- Razonamiento Inductivo fuzzy (FIR).
- Redes Neuronales Artificiales (ANN).
- Métodos Híbridos.

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

#### Estructura del Sistema Multivariable

En la Tabla 1 se muestra la estructura del sistema multivariable del problema a plantear para el pronóstico de demanda, donde se observan las series temporales que se consideran.

TABLA 1: Sistema Multivariable para el Pronóstico

[A]	[E]	[F]
day(t-n)	TM_C(t-n)	load(t-n)
...	...	...
day(t-1)	TM_C(t-1)	load(t-1)
day(t)	TM_C(t)	load(t)

Donde:

- A = Variable tipo de día (lunes, ..., domingo).
- E = Variable temperatura máxima de la costa.
- F = Variable demanda.

### 4. METODOLOGÍA DE PRONÓSTICO BASADA EN RAZONAMIENTO INDUCTIVO FUZZY Y ALGORITMOS EVOLUTIVOS

La metodología Fuzzy Inference Reasoning (FIR), ver Figura 1, 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 y predecir el comportamiento futuro de una serie temporal (demanda).

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.




FIGURA 1: Metodología FIR

### Fuzzyficación

Incrementa 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.

#### 1) Tipo de Día

Esta variable se la fuzzyfica en cuatro clases (lunes, martes a viernes, sábado y domingo). La fuzzyficación se muestra en la Tabla 2.

TABLA 2: Fuzzyficación de la Variable Tipo de Día

[A]	CLASS	CODIFICACIÓN	MEMBERSHIP	SIDE
Lunes	Laboral 1	1	1	0
Martes	Laboral 2	2	1	0
Miércoles	Laboral 2	2	1	0
Jueves	Laboral 2	2	1	0
Viernes	Laboral 2	2	1	0
Sábado	Semilaboral	3	1	0
Domingo	No laboral	4	1	0

El día lunes (laboral 1) se lo diferencia de los demás días normales de trabajo (laboral 2), ya que este día posee un factor inercial en las horas de la mañana debido a la terminación del fin de semana (demanda menor a la media esperada).

#### 2) Temperatura

La temperatura se la fuzzyfica en 2 clases. En la Tabla 3 se muestran los límites de las funciones

de membresía y la respectiva fuzzyficación para la temperatura máxima de la Costa.

TABLA 3: Fuzzyficación de la Variable Temperatura

[E]	CLASS	COD	MEMBER	SIDE
[25,27[	Templado	1	1	0
[27,35]	Cálido	2	1	0

Las funciones que se utilizan para la fuzzyficación de la variable tipo de día y temperatura son funciones trapezoidales y se muestran en la Figura 2.




FIGURA 2: Funciones Trapezoidales para la Variable Tipo de Día y Temperatura Máxima de la Costa

#### 3) Demanda

Para modelar la demanda del Sistema Ecuatoriano se realiza una división de clases (utilizando la misma división que la variable tipo de día: lunes, martes a viernes, sábado y domingo) como se muestra en la Figura 3, se incluye el diagrama de duración de carga y el histograma respectivo.

La particular distribución de los datos en los histogramas define de una manera "natural": cuatro clases para los días lunes a viernes: pico, media, resto y valle; tres clases para el día sábado: pico, media y valle, y dos clases para el día domingo: pico y valle. Para estimar los landmarks de cada unas de las clases para la variable demanda se utilizó el algoritmo de clasificación fuzzy c-means.

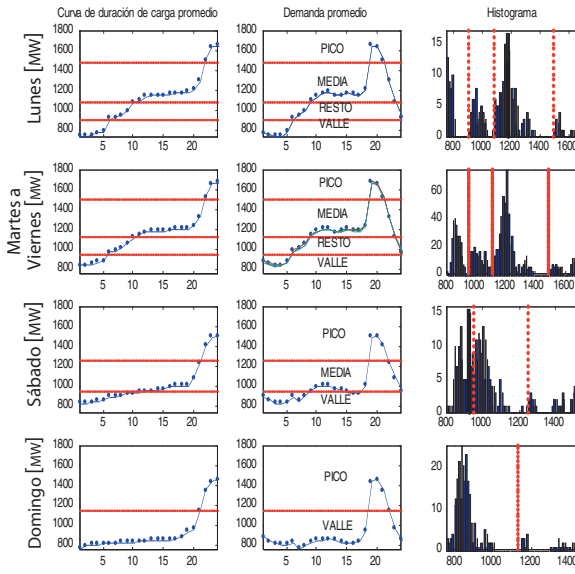


FIGURA 3: Modelación de la Demanda del SSEE del Ecuador

El proceso de fuzzyficación se muestra en la Figura 4.

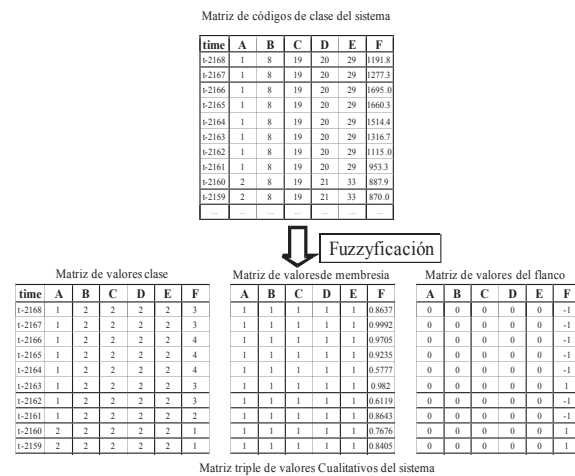


FIGURA 4: Fuzzyficación del Sistema Multivariable

### Modelación Cualitativa

La modelación cualitativa determina el grupo de variables de entrada (máscara de correlación) que mejor explican el comportamiento entrada – salida. El número de filas de la máscara es conocida como la profundidad y está directamente relacionada con la observación histórica del sistema. Se utiliza la función de autocorrelación parcial (ACF), la cual muestra la correlación que existe en la serie temporal. La variable de interés que determinará la profundidad de la máscara será la demanda, en la demanda tiene dos estacionalidades (diaria y semanal), por lo que se escoge para la profundidad de la máscara un valor

de 25 (desde t hasta t-24, donde el valor de t para la demanda es el pronóstico de demanda). La profundidad considerando la estacionalidad semanal se desprecia ya que es computacionalmente ineficiente.

Una relación cualitativa para el pronóstico de demanda que incluya las variables “tipo de día”, “temperatura máxima de la Costa” y “demanda histórica”, podría estar dada por la ecuación (1), que relaciona el pronóstico de la demanda en (t) con el tipo de día en (t-5), la temperatura máxima de la Costa en (t) y la demanda histórica en 1, 2, 4, 14, 23 y 24 horas anteriores a (t).

$$F_{(t)} = \tilde{f}(A_{(t-5)}, E_{(t)}, F_{(t-24)}, F_{(t-23)}, F_{(t-14)}, F_{(t-4)}, F_{(t-2)}, F_{(t-1)}) \quad (1)$$

Donde:

$\tilde{f}$  = Es un funcional que denota una relación cualitativa genérica (patrón de entrada - salida) de las variables de entrada.

### Búsqueda de la Máscara Óptima

En este trabajo se plantea resolver un problema de optimización para encontrar máscaras de correlación que tienen un mejor comportamiento comparadas con las máscaras encontradas por la metodología FIR tradicional, utilizando Algoritmos Evolutivos para determinar las entradas de la máscara de correlación como se explica más adelante.

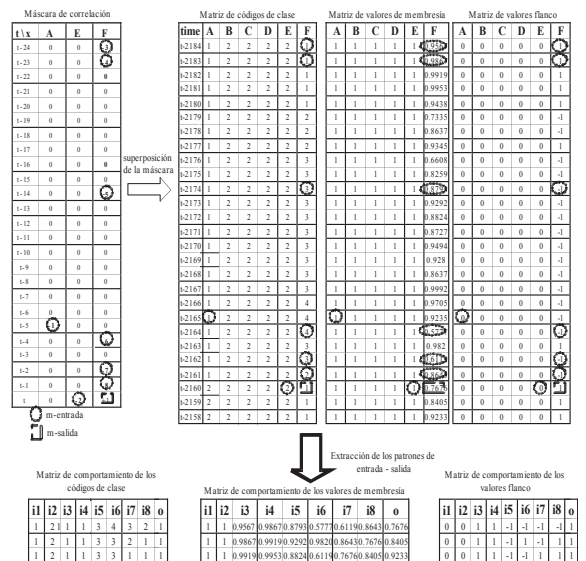


FIGURA 5: Construcción de la Matriz de Comportamiento

La función de la máscara es seleccionar las m-entradas y la salida en cada matriz de clase, membresía y flanco, y transformar dichos valores en patrones estáticos de entrada – salida (estados del sistema). Desplazando

la máscara de correlación sobre las matrices de clase, membresía y flanco, se obtienen distintos estados del sistema explicativos del comportamiento del mismo en el tiempo. El conjunto de estados del sistema es conocido como "Matriz de Comportamiento" o "Rule Base" (base de conocimiento). La Figura 5 muestra cómo se realiza la construcción de la "matriz de comportamiento".

### Simulación Cualitativa

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. La máscara se ubica al final de la matriz de valores clase y se extraen las m-entradas (patrón de valores clase), los cuales son comparados en la matriz clase de comportamiento para obtener los valores clase futuros de la salida. Además, se extraen los valores de membresía y flanco de los estados correspondientes. El esquema de pronóstico fuzzy se muestra en la Figura 6.

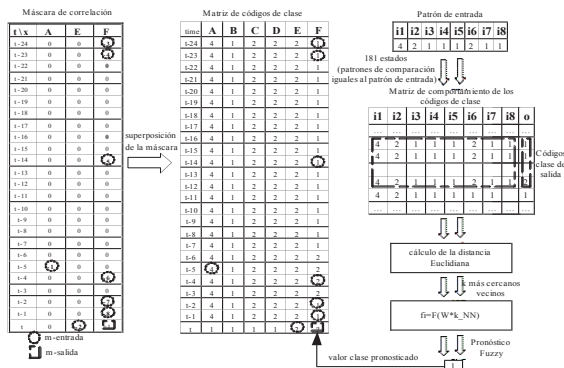


FIGURA 6: Pronóstico Fuzzy

### Defuzzyficación

Las predicciones de los valores de membresía, flanco y código de clase de la salida pronosticada son convertidas a predicciones cuantitativas usando la operación inversa a la fuzzyficación como se muestra en la Figura 7.

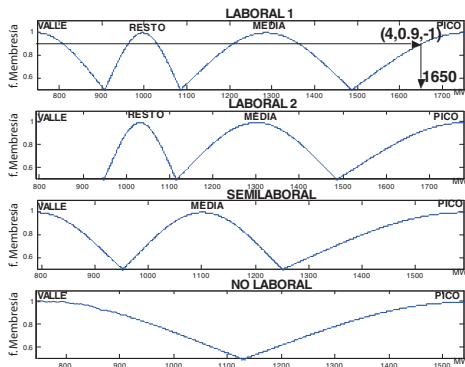


FIGURA 7: Defuzzyficación

En la Figura se ha supuesto que el estado observado (4,2,1,1,1,2,1,1) tiene una salida pronosticada igual al triple (4;0,9;-1), el cual - mediante el proceso de defuzzyficación - da un valor para el pronóstico de demanda del día lunes a las 18:00 para el SSEE del Ecuador de 1 650 MW.

### 4.1. Algoritmos Evolutivos

#### La Simulación del Proceso Físico de Rebotes Simulados (SRA)

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 está 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 esta 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 8 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 o 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 ( $\alpha$ ), permiten saltar todos los mínimos locales durante el proceso de rebotes.




FIGURA 8: Ejemplo Unidimensional de Rebotes Simulados

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

- Deformación transitoria, es decir, que la pelota no pierde energía cinética por ser la altura de la caída pequeña.
- 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.
- Deformación permanente, cuando la pelota pierde energía cinética debido a una colisión provocada por una altura considerable de caída.

El pseudocódigo del SRA se muestra a continuación:

```

solución_rebounding (solución x, real  $\alpha$ , real d)
{
    solución vn
    real  $\beta$ ,  $\delta$ ,  $E_0$ ,  $E_1$ ,  $F_v$ ,  $F_{vn}$ 

     $F_v = \text{PDMCP}(v)$ ;
     $E_0 = F_v / \alpha$ ; // energía inicial de la pelota
     $\beta = (E_0 - F_v) / 1, 1/d$ ; // decremento choques
    frustrados
     $\delta = (9 + \alpha) / 10$ ; // decremento por rozamiento

    do
    {
         $E_1 = \alpha * E_0$ ; // próximo nivel de E. (colisión inelástica)
        do
        {
             $vn = \text{vecino\_de}(v)$ ;
             $F_{vn} = \text{PDMCP}(vn)$ ;
            if ( $\delta * E_0 < F_{vn}$ ) // DL (rebote frustrado)

```

```

{
     $E_0 = E_0 - \beta$ ;
}
else if ( $E_1 \leq F_{vn}$ ) // DT (choque elástico)
{
     $v = vn$ ;
     $F_v = F_{vn}$ ;
     $\beta = (E_0 - F_v) / 1, 1/d$ ;
}
else // DP (choque inelástico)
{
     $E_0 = E_1$ ;
     $v = vn$ ;
     $F_v = F_{vn}$ ;
     $\beta = (E_0 - F_v) / 1, 1/d$ ;
    break do; // recalculer energía
}
} while ( $F_v \leq E_0$ );
} while ( $F_v \leq E_0$ );
return (v); // retorna la solución encontrada

```

## 5. ANÁLISIS DE RESULTADOS

Existen algunas causas que ocasionan los desvíos de la demanda, pero para nuestro estudio nos enfocamos en las que son producidas por los cambios bruscos en las costumbres de los consumidores, cambios climáticos o factores aleatorios que generan errores considerables en ciertas horas del día.

En la actualidad el redespacho por desviaciones considerables de demanda, es una tarea que depende del criterio del operador para establecer la hora de vigencia en que se iniciaría el reajuste del pronóstico de la demanda para las horas restantes del día.

Por lo que, es de suma importancia el nuevo pronóstico de la demanda que considere la nueva tendencia en el comportamiento de la demanda, actualmente en la Dirección de Operaciones el pronóstico de la demanda está basado en promedios aritméticos y no se tiene hoy en día una herramienta formal para este análisis.

Razón por la cual, en este punto se consideró que antes de realizar un reajuste de la demanda con la metodología FIR, se debía encontrar un "criterio de arranque" que permita establecer con anticipación la hora en que daría inicio el cálculo del nuevo pronóstico para las horas restantes del día.

### Criterio de Arranque

Para el análisis de valores atípicos se considera el histograma de los errores relativos generados por la



metodología FIR con un horizonte de tiempo de 24 horas en adelante durante un período de un mes desde el 11 de septiembre del 2000 hasta el 9 de octubre del 2000, el cual se muestra en la Figura 9.

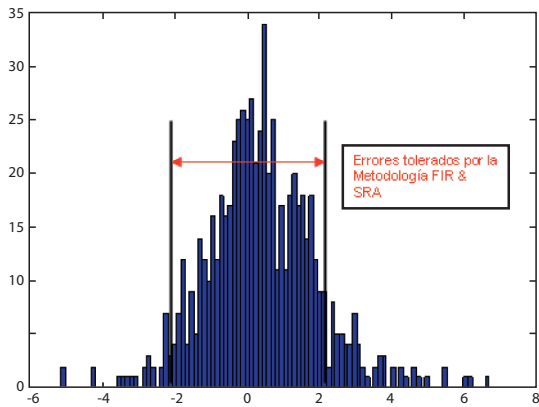


FIGURA 9: Histograma de los Errores con FIR & SRA

La forma del histograma se asemeja a una distribución normal  $N(\mu, \sigma)$  de media 0,38 y desviación estándar 1,51.

En una distribución normal el 99,73% de las observaciones se encuentran en el intervalo  $[\mu - 3\sigma, \mu + 3\sigma]$  y está definida por la ecuación (2).

$$Y = \frac{1}{\sigma \sqrt{2\pi}} e^{-\frac{1}{2} \left( \frac{x - \mu}{\sigma} \right)^2} \quad (2)$$

En este estudio, para encontrar un valor que sirva de umbral para el análisis de valores atípicos, se puede considerar el intervalo, el cual contiene errores relativos menores al 2% y cuya área se obtiene cuando se expresa la variable  $x$  (errores relativos) en unidades estándar  $[z = (x - \mu) / \sigma]$  permitiendo remplazar la ecuación (2) por la llamada forma canónica, (ver ecuación (3)).

$$Y = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2} z^2} \quad (3)$$

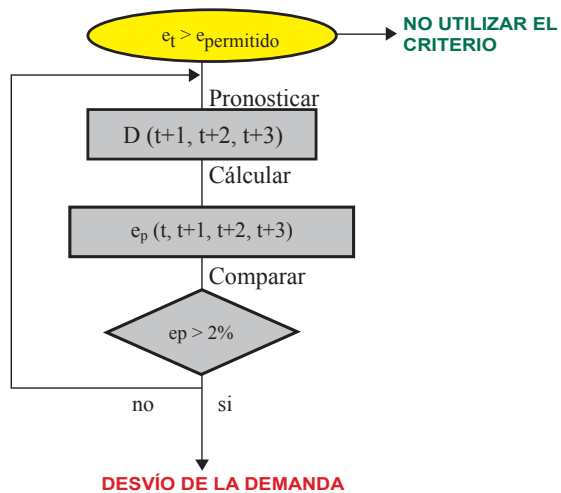
En tal caso, decimos que  $z$  está normalmente distribuida con media igual a cero (0) y varianza uno (1), con esto se puede hacer uso de las tablas que permiten hallar el área comprendida en el intervalo seleccionado.

Entonces se puede calcular el área comprendida entre el intervalo más/menos 2%, dicha área corresponde al 79,48% que representa a los errores tolerables por la metodología FIR & SRA y los valores fuera de ella se consideran como valores atípicos, es decir la

demanda programada no refleja el comportamiento de la demanda real.

Una vez detectado este error umbral se procederá a verificar si la variación o el comportamiento de la demanda ha cambiado con respecto a la programada mediante el siguiente flujograma.

Para lo cual, se considera a la demanda calculada con la metodología FIR como la demanda real, debido a su mejor performance mostrado en Investigaciones anteriores.



Donde:

$$e_{\text{umbral}} = 2\%$$

$D(t+1, t+2, t+3)$  = Pronóstico de la demanda para las siguientes tres horas en adelante.

$e_p$  = Error promedio de las tres horas previstas.

El cual ha proporcionado muy buenos resultados estableciendo la hora de vigencia para el nuevo cálculo del pronóstico de la demanda como se muestra en el siguiente ejemplo.

**Ejemplo:** Se considera el día martes 25 de julio del 2000, en el que se realizó un reajuste de la demanda a partir de las 17:00, por parte del Área de Centro de Operaciones (ACDO) del CENACE, como se muestra en la Tabla 4 - columna 5, debido a la variación drástica de la tendencia de la demanda con respecto a la programada.

**Procedimiento:** Una vez detectado, que el error a la hora  $t$  supera el 2%, se aplica el “criterio de arranque”, para determinar si la variación es momentánea o permanente.

Si la variación es momentánea como se muestra en la Tabla 4, no se realiza ningún reajuste de la demanda, debido a que el error promedio ( $e_t, e_{t+1}, e_{t+2}, e_{t+3}$ ) no supera el 2%.

TABLA 4: Aplicación del Criterio de Arranque a la 1 am

Hora	Programada	Real	Error %	PDMCP con FIR&SRA_3h adelanto	err_3h adelanto
0-1	890,2	870,4	2,777		2,277
1-2	873,0			848,2	1,720
2-3	855,4			841,9	1,606
3-4	871,2			841,9	2,261
				<b>Promedio</b>	<b>1,966</b>

Caso contrario, es decir si el error promedio de ( $e_t, e_{t+1}, e_{t+2}, e_{t+3}$ ) superar el 2%, como se visualiza en la Tabla 5 se realiza un nuevo pronóstico de la demanda para las restantes horas del día. Se demuestra que basta la información de dos

horas de la demanda real para detectar el nuevo comportamiento de la demanda.

TABLA 5: Aplicación del Criterio de Arranque a las 2am

Martes 25 de julio del 2000					
Hora	Programada	Real	Error %	PDMCP con FIR&SRA_3h adelanto	err_3h adelanto
1-2	873,0	849,7	2,745		2,745
2-3	855,4			841,9	1,580
3-4	871,2			841,9	3,359
4-5	911,1			841,9	7,589
				<b>Promedio</b>	<b>3,818</b>

El nuevo pronóstico se muestra en la Tabla 6 - columna 7 con los respectivos errores cometidos hora a hora a partir de las tres de la mañana (3 am) y el error promedio al final del día que se reduce en un 80,26% al obtenido por el operador (Tabla 6 - columna 6) con el respectivo ajuste que lo hicieron a partir de 17:00.

TABLA 6: Reajuste de la Demanda a Partir de las 3 am

Martes 25 de julio del 2000							
Hora	Programada	Real	err_progra(%)	Reajuste	err_reajuste(%)	FIR	err_FIR(%)
0- 1	890,2	870,4	2,277		2,277		2,277
1- 2	873,0	849,7	2,745		2,745		2,745
2- 3	855,4	831,9	2,831		2,831	831,9	0,004
3- 4	871,2	837,5	4,023		4,023	831,7	0,697
4- 5	911,1	871,4	4,553		4,553	865,0	0,737
5- 6	1 050,4	1 002,90	4,741		4,741	979,7	2,317
6- 7	1 107,6	1 025,9	7,961		7,961	1 000,5	2,478
7- 8	1 115,4	1 051,3	6,101		6,101	1 046,2	0,487
8- 9	1 242,0	1 135,6	9,372		9,372	1 139,0	0,301
9- 10	1 280,4	1 168,6	9,572		9,572	1 171,9	0,289
10- 11	1 313,2	1 196,0	9,808		9,808	1 202,5	0,544
11- 12	1 314,3	1 193,3	10,146		10,146	1 200,9	0,644
12- 13	1 298,6	1 172,1	10,796		10,796	1 173,1	0,087
13- 14	1 322,7	1 188,8	11,266		11,266	1 184,2	0,389
14- 15	1 369,0	1 215,0	12,682		12,682	1 192,0	1,886
15- 16	1 373,8	1 208,2	13,712		13,712	1 191,8	1,350
16- 17	1 329,4	1 187,4	11,956	1 203,0	1,313	1 175,7	0,983
17- 18	1 291,7	1 210,5	6,712	1 188,3	1,832	1 221,7	0,927
18- 19	1 781,4	1 680,7	5,991	1 728,0	2,813	1 667,8	0,766
19- 20	1 761,5	1 687,9	4,360	1 710,2	1,318	1 646,5	2,453
20- 21	1 613,6	1 555,9	3,709	1 568,8	0,832	1 516,8	2,515
21- 22	1 406,9	1 343,6	4,709	1 329,8	1,027	1 330,4	0,983
22- 23	1 162,2	1 119,8	3,789	1 095,6	2,156	1 111,5	0,737
23- 24	980,3	959,5	2,177	925,7	3,52	954,4	0,525
<b>promedio</b>			<b>6,916</b>		<b>5,725</b>		<b>1,130</b>



En la Tabla 7 podemos apreciar los errores promedios al final del día para cada uno de los ejemplos analizados y apreciar que con la metodología FIR & SRA los errores promedios se hubieran reducido en 60% con respecto al metodología utilizada por el CENACE (ARIMA).

TABLA 7: Resumen de los Días Analizados

Día	err_programado CENACE (%)	Metodología FIR & SRA (%)
25-jul-2000	5,725	1,13
20-nov-2000	1,665	1,47
9-oct-2000	4,402	1,192
1-nov-2000	2,205	1,807
<b>promedio</b>	<b>3,499</b>	<b>1,400</b>

## 6. CONCLUSIONES

La principal ventaja del Modelo de Simulación con FIR para el Pronóstico de Demanda de Muy Corto Plazo propuesto para la Dirección de Operaciones, radica en que puede utilizar la información de las últimas horas para poder predecir la nueva tendencia de la demanda del Sistema Eléctrico, minimizando las desviaciones de la demanda programada con respecto a la real. Estas desviaciones se pueden dar por cambios súbitos en el clima o factores aleatorios (paros, huelgas, etc.) que no fueron considerados en el Pronóstico de Corto Plazo.

El pronóstico de la demanda de muy corto plazo como se demostró, permitirá a la Dirección de Operaciones del CENACE, realizar un seguimiento de la demanda y de ser necesario plantear una nueva optimización del parque hidro - térmico (vía Redespacho) debido a causales de desviación considerable de la demanda o por falta de Margen de Reserva en el Sistema.

El criterio de arranque permitirá al operador establecer la mejor estrategia para cubrir las desviaciones de demanda producidas en el sistema.

## 7. BIBLIOGRAFÍA

[1] ARGUMOSA D.; Planificación de la Expansión de Sistemas de Distribución, Instituto de Energía Eléctrica de la Universidad Nacional de San Juan, Argentina, 2002.

[2] BEZDEK J. C.; Fuzzy Mathematics in Pattern Classification, Tesis doctoral, Centro de Matemáticas Aplicadas, Universidad de Cornell, 1973.

[3] HINOJOSA V.; Pronóstico de Demanda de Corto Plazo en Sistemas de Suministro de Energía Eléctrica Utilizando Inteligencia Artificial, Tesis Doctoral, Instituto de Energía Eléctrica de la Universidad Nacional de San Juan, Argentina, 2007.

[4] LOTUFO A. D. y MINUSSI C. R.; Electric Power Systems Load Forecasting: A Survey, IEEE Power Tech, Hungría, 1999.



**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.



**Lorena Herrera Orbea.-** Nació en Latacunga, Ecuador en 1981. Recibió su título de Ingeniero Eléctrico en la Escuela Politécnica Nacional en el 2007. Actualmente colabora en la Dirección de Transacciones Comerciales del CENACE.

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