

METODOS DE PRONOSTICO DE DEMANDA A CORTO PLAZO PARA LA

OPERACION DE SISTEMAS DE POTENCIA

INSTITUTO ECUATORIANO DE ELECTRIFICACION

Santiago Sánchez M.

Centro Nacional de Control de Energía

IEEE - Sección Ecuador

RESUMEN

En este trabajo se presenta los conceptos generales y algunos métodos para realizar el pronóstico de la demanda para la operación de un sistema de potencia. Se pone especial interés en el método de Box & Jenkins, de pronóstico de corto plazo, y se describe la metodología y la teoría matemática de los modelos ARMA de pronóstico. Se presenta la aplicabilidad de estos modelos para el pronóstico mensual y horario de un sistema en particular, comprobándose la bondad y exactitud de los modelos y de la metodología empleada.

INTRODUCCION

La planificación de un sistema de potencia consiste en determinar las necesidades de recursos de la red eléctrica para períodos futuros. La operación del sistema requiere conocer la demanda con la debida anticipación para hacer la distribución óptima de los recursos disponibles.

El presente trabajo pretende describir los métodos más conocidos y usados en pronóstico de demanda, con énfasis en el pronóstico a corto plazo, o pronóstico horario, con el propósito de conocer la aplicabilidad de estos métodos en el control en tiempo real del sistema ecuatoriano, y luego adentrarse en los detalles particulares y en la metodología de Box & Jenkins que utiliza los modelos ARMA, de pronóstico.

La base estadística presentada en los diferentes modelos es general y puede aplicarse no solamente a estudios de demanda eléctrica sino a todo proceso estadístico o serie de tiempo.

Actualmente los métodos de pronóstico para operación de sistemas de potencia utilizados en el país se basan en criterios tradicionales que dependen de la experiencia de quien hace el pronóstico, y no consideran una base matemática. Esto trae como consecuencia que los resultados del pronóstico en su mayoría no sean confiables, debiéndose mantener una reserva de generación excedente que implica un costo. La posibilidad de aplicar un modelo matemático al pronóstico debe ser considerada, pues se puede incluir criterios que proporcionan un pronóstico más exacto y confiable.

En el Proyecto Centro Nacional de Control de Energía, es vital poder disponer de una función de pronóstico de demanda a corto plazo, pues se permitiría que la distribución de la carga y la generación se realicen en forma óptima y con mayor seguridad.

En el trabajo se ha desarrollado dos ejemplos de aplicación del método de Box & Jenkins. El primero es el pronóstico mensual de la demanda del sistema de la Empresa Eléctrica Quito, en tanto que el segundo es el pronóstico horario total de esta misma empresa. Los resultados obtenidos en estos ejemplos demuestran que el método utilizado es bastante exacto.

ASPECTOS GENERALES DE PRONOSTICO DE DEMANDA

En términos generales lo que se trata en un método de pronóstico es obtener valores futuros de un fenómeno histórico, dado su comportamiento pasado. Se asume, siendo esta una premisa fundamental en pronóstico, que el comportamiento se mantendrá durante el tiempo del estudio.

Análisis de la Demanda

Se define la demanda eléctrica como el factor determinante de un sistema de potencia, y representa la magnitud de energía que requiere un equipo eléctrico para su funcionamiento.

Previo a aplicar un método de pronóstico, se requiere realizar un estudio de la variable demanda para aplicar el método adecuado y obtener un pronóstico acertado. Cuatro son los aspectos principales en el análisis de la demanda:

- a) Variable a pronosticar
Se debe determinar qué es lo que vamos a pronosticar: La potencia, la energía, los costos asociados a la demanda, las fallas del sistema, etc.
- b) Comportamiento de la demanda en el tiempo
Del análisis del comportamiento de la demanda en la historia de los datos, se puede determinar inicialmente si el fenómeno se mantendrá en el futuro y de ciertos parámetros iniciales útiles para el pronóstico y para la selección del método a usar.
- c) Plazo de la predicción
Se requiere conocer cuál es el período del pronóstico. En planificación se habla de períodos anuales o mensuales en tanto que en operación del sistema los períodos son de días e incluso de horas y minutos.
- d) Factores que afectan a la demanda
La fluctuación de la demanda en el transcurso del tiempo es un proceso aleatorio que depende de un sin número de factores, los que hacen casi imposible definir el comportamiento individual de la carga. Sin embargo, al agrupar la carga, el comportamiento es más definido y puede ser tratado.

Los factores que afectan a la demanda pueden ser de dos tipos:

1) Factores incontrolables, sobre los cuales el operador no tiene un control directo, como son: Factores políticos y económicos, factores atmosféricos, aleatoriedad de la carga, límites físicos del sistema, etc.

2) Factores controlables, sobre los cuales el operador tiene un control, como son por ejemplo la potencia, la frecuencia y el voltaje.

Mediante el análisis de los cuatro aspectos planteados, se puede tener una idea cierta de la variable a pronosticar y de los factores necesarios para el pronóstico.

Análisis de los datos

Otro aspecto importante en el análisis de la demanda es la calidad y confiabilidad de los datos. Si los datos son errados, no importa qué método se utilice, el resultado será errado. Puede ser beneficioso en muchos casos filtrar los datos, es decir mediante un análisis preliminar corregir observaciones erradas para obtener una serie de trabajo que sea representativa del fenómeno a pronosticar.

MÉTODOS DE PRONOSTICO

Clasificación

En general, los métodos de pronóstico pueden clasificarse en dos grupos: cualitativos y cuantitativos.

a) Métodos Cualitativos: Consisten en la aplicación de criterios sin base estadística y se basan en el ajuste de curvas mediante la experiencia o el criterio del que hace el pronóstico.

b) Métodos Cuantitativos: Toman la información histórica de un fenómeno y tratan de encontrar un modelo que explique matemáticamente esta tendencia pasada, para así pasar a predecir los períodos futuros de ese fenómeno. La subclasificación de los modelos cuantitativos se la resume en la Figura 1 y se los detalla más adelante.




Figura 1: Clasificación de los métodos cuantitativos.

Métodos Causales

Un método causal o aplicativo es aquel en que cierto número de parámetros, conocidos como variables independientes, tienen una relación matemática con la variable a pronosticar, o variable dependiente. El mayor problema en estos modelos es determinar la relación entre las variables independientes y la variable dependiente que explique mejor

el fenómeno. El método causal más conocido es el método de regresión.

1) Método de Regresión

El modelo de regresión múltiple tiene la forma polinomial:

$$y = \beta_0 + \beta_1 x_{t1} + \beta_2 x_{t2} \dots + \beta_n x_{tn} + \epsilon_t \quad (1)$$

donde: β_0 es la tendencia o pendiente.

β_i son los parámetros del modelo que ajustan los datos.

x_{ti} son los datos de las variables independientes para el período del pronóstico.

ϵ_t es un error aleatorio (o ruido blanco).

Para usar este método se escoge las variables independientes y luego se calcula los estimados de β_i , (b_i), por el método de los mínimos cuadrados, que da la mejor curva de ajuste al reducir al mínimo la suma del cuadrado de los errores. Las variables independientes no se relacionan entre sí y se dispone de varios conceptos estadísticos para determinar qué variables son importantes.

En pronóstico de demanda un método de regresión muy utilizado es aquel que representa a las variables independientes como funciones trigonométricas de senos y cosenos, el mismo que se conoce como un análisis espectral de la serie en el dominio de la frecuencia. La serie original se descompone mediante un análisis de Fourier en series más pequeñas donde se puede determinar la importancia de cada término. Si la descomposición es correcta se elimina la componente del ruido. Los métodos de regresión tienen una base estadística.

Métodos de Series de Tiempo

Una serie de tiempo es cualquier conjunto de observaciones ordenadas en el tiempo. A diferencia de los modelos causales, los modelos de series de tiempo no necesitan de variables independientes sino que pronostican en base a los mismos valores pasados de la variable a pronosticar.

Los métodos de series de tiempo que se utilizan más comúnmente son: suavizamiento, descomposición, y modelos ARMA o de Box & Jenkins. Estos últimos se los detallará más adelante.

1) Métodos de Suavizamiento

Los métodos de suavizamiento o alisamiento pretenden eliminar el ruido existente en una serie de tiempo para encontrar la tendencia o patrón de comportamiento. Una vez encontrado este patrón se podrá hacer el pronóstico. Las técnicas de suavizamiento más conocidas son:

a) Medias Móviles: es una técnica que consiste en tomar un conjunto de valores observados, encontrar el promedio de los mismos y usar este promedio como el pronóstico del siguiente período. El número de observaciones (N) es siempre cons

tante. Matemáticamente tenemos:

$$y_{t+1} = (x_t + x_{t-1} + \dots + x_{t-N+1})/N \quad (2)$$

$$= \frac{1}{N} \sum_{i=t-N+1}^t x_i \quad (3) = \frac{x_t}{N} - \frac{x_{t-N}}{N} + y_t \quad (4)$$

b) Suavizamiento Exponencial: Esta técnica da mayor peso a las observaciones más recientes y requiere solamente de los dos últimos datos para hacer el pronóstico. De la Ecuación 4, si se reemplaza x_{t-N} por el pronóstico reciente y_t , se tiene:

$$y_{t+1} = \frac{1}{N} x_t + (1 - \frac{1}{N}) y_t \quad (5)$$

Si $\alpha = \frac{1}{N}$, entonces

$$y_{t+1} = \alpha x_t + (1 - \alpha) y_t \quad (6)$$

La importancia de una observación va decreciendo a medida que se aleja de la observación más reciente y en forma exponencial.

2) Método de Descomposición

El método de descomposición supone que la serie de tiempo está conformada por cuatro componentes que pueden separarse y calcularse individualmente mediante manipulaciones matemáticas apropiadas. Estas componentes son:

- Tendencia (T), dada por los movimientos hacia arriba o hacia abajo de la serie total.
- Componente Cíclica (C), dada por los movimientos ascendentes o descendentes de la serie en forma global cada cierto período.
- Componente Estacional (E), que representa los movimientos que se repiten en forma periódica anualmente.
- Componente Irregular (I), dada por los movimientos erráticos o impredecibles de la serie.

Si la relación entre los componentes es multiplicativa, se tiene:

$$y_t = T_t * E_t * C_t * I_t \quad (7)$$

Para hacer el pronóstico y_t , se debe conocer los valores de cada una de las componentes del período a pronosticar. Los métodos de descomposición y suavizamiento no tienen una base estadística.

Modelo con Filtro de Kalman

El tipo de modelos que utilizan el Filtro de Kalman son adaptivos, es decir que, a diferencia de los modelos causales y de series de tiempo, los parámetros de la serie se ajustan automáticamente con cada nueva observación y pueden operar con parámetros variables y varianza variable simultáneamente.

El Filtro de Kalman (1960) es la técnica más general de pronóstico y fue desarrollado para análisis de señales. Consiste en combinar dos estimados independientes, uno que es un pronóstico anterior de la serie

(a priori) y el otro que es un pronóstico basado en nuevos datos (a posteriori), para formar un estimado ponderado o pronóstico. Es un método matricial conocido también como método Bayesiano de predicción, y utiliza un procedimiento recursivo para realizar los ajustes en el pronóstico. En poco tiempo el Filtro de Kalman será utilizado en muchos campos y especialmente en corrección de valores de una medición y en pronóstico de demanda, donde se presenta como la vía más factible para el pronóstico y control en tiempo real.

Método de Box & Jenkins

Las técnicas de regresión, de suavizamiento y de descomposición asumen que los datos de la serie de tiempo son estadísticamente independientes y que no existe relación entre ellos. Si los datos de la serie están relacionados o son dependientes estadísticamente entre sí, los modelos de Box & Jenkins usan esta dependencia para producir un pronóstico que tiene a ser más exacto, ya que es obvio suponer que un dato pasado, está relacionado de alguna manera con el dato actual. En vista de que existe relación entre los datos, se dice que hay correlación entre ellos, y ya que el pronóstico se hace en base a los valores de la misma serie, se conoce como AUTOCORRELACION.

El método de Box & Jenkins ha sido, desde su introducción en el año 1970 por parte de George Box y Gwilym Jenkins, bastante usado en pronósticos de series de tiempo por sus favorables cualidades, especialmente en pronóstico de corto plazo. Estos modelos requieren de un gran número de observaciones (más de 50) y de un procedimiento conocido como Metodología de Box & Jenkins, para su efectiva aplicación.

Modelos ARMA

Los modelos ARMA, o de Box & Jenkins suponen que la serie de tiempo es generada a través de un filtro lineal, cuya entrada es ruido blanco, definiendo al ruido blanco como un proceso aleatorio generado por variables aleatorias normales independientes, con media cero y varianza σ^2 . Si se logra modelar exactamente la función de transferencia del filtro ($\psi(B)$), en el proceso inverso, al introducir la serie de tiempo y_t , se deberá obtener ruido blanco ϵ_t (Figura 2).




Figura 2. Filtro Lineal

Desarrollando matemáticamente el filtro lineal y dado que las observaciones de la serie tienen sus errores correlacionados obtenemos:

$$y_t = \mu + \psi_0 \epsilon_t + \psi_1 \epsilon_{t-1} + \psi_2 \epsilon_{t-2} + \dots \quad (8)$$

donde μ y ψ_j son los parámetros descritos en la Ec. (1).

Agrupando términos en la Ecuación (8) se tiene:

$$y_t = \mu + (\psi_0 + \psi_1 B + \psi_2 B^2 + \dots) \varepsilon_t \quad (9)$$

donde: B se define como un OPERADOR REGULAR REGRESIVO tal que:

$$B y_t = y_{t-1}, \dots, B^m y_t = y_{t-m}$$

La Ecuación (9) puede escribirse como:

$$y_t = \mu + \psi(B) \varepsilon_t \quad (10)$$

donde: $\psi(B)$ es la función de transferencia del filtro lineal.

Si queremos expresar los errores ε_t en función de los datos de la serie, se tiene:

$$y_t \psi^{-1}(B) = \mu \psi^{-1}(B) + \varepsilon_t \quad \text{o re-}$$

definiendo:

$$y_t \phi(B) = \delta + \varepsilon_t \quad (11)$$

donde: $\delta = \mu \psi^{-1}(B)$, $\phi(B) = \psi^{-1}(B)$

Las expresiones (10) y (11) son las ecuaciones básicas de los modelos de Box & Jenkins.

Conceptos Básicos

- PROCESO ESTACIONARIO. Es condición de los modelos ARMA, que la serie de la Ecuación (8) sea finita y sus valores fluctúen alrededor de una media constante. A esta condición se la conoce como ESTACIONARIDAD, por lo cual la serie de trabajo, o serie a pronosticar debe ser una serie estacionaria. De no satisfacerse esta condición, mediante algunos artificios u operaciones matemáticas se puede lograr transformar una serie original no estacionaria y_t , en otra serie de trabajo estacionaria z_t . Una manera de obtener esta transformación es mediante la operación de DIFERENCIACIÓN, que consiste en restar de cada observación su predecesora. Para esto se define un OPERADOR REGULAR DE DIFERENCIACIÓN ∇ tal que $\nabla = 1 - B$, de modo que:

$$z_t = \nabla y_t = (1-B)y_t = y_t - By_t = y_t - y_{t-1} \quad (12)$$

En forma general para un número d de diferencias regulares

$$\nabla^d y_t = (1-B)^d y_t \quad (13)$$

Usualmente no se requiere más de dos diferencias para obtener la estacionaridad de la serie.

- FUNCIONES DE AUTOCORRELACION Y DE AUTOCORRELACION PARCIAL.

Una serie de tiempo estacionaria supone que las mediciones estadísticas entre n observaciones a partir del origen t, tienen las mismas relaciones entre n observaciones

a partir del origen t+j.

Para medir la significación de dos mediciones separadas k periodos la una de la otra, se usa la FUNCION DE AUTOCORRELACION, ρ_k , dada por:

$$\rho_k = \frac{\text{Cov}(z_t, z_{t+k})}{\text{Var}(z_t)} \quad (14) \quad -1 \leq \rho_k \leq 1$$

donde: $\rho_k = -\rho_k$

Si no consideramos los efectos de las observaciones intermedias entre las k observaciones, se tiene la FUNCION DE AUTOCORRELACION PARCIAL, ρ_{kk} , artificio creado por Box & Jenkins.

Como el proceso aleatorio que origina la serie es infinito, los valores de ρ_k y de ρ_{kk} no se pueden calcular con exactitud, por lo que se utilizan sus estimados muestrales r_k y r_{kk} , cuyas definiciones se dan en el Apéndice.

Al identificar los modelos ARMA, es decir al encontrar los parámetros del modelo, las funciones de autocorrelación y de autocorrelación parcial son herramientas básicas, y se resume su comportamiento en el Apéndice.

A continuación se describirá los modelos ARMA.

Modelos Autoregresivos AR(p)

Desarrollando la Ecuación (11) y ordenando términos, se tiene:

$$z_t = \delta + \phi_1 z_{t-1} + \phi_2 z_{t-2} + \dots + \phi_p z_{t-p} + \varepsilon_t \quad (15)$$

La Ecuación (15) es la ecuación de un modelo autoregresivo de orden p o AR(p). Se dice que es autoregresivo pues el valor actual de la serie se expresa como una combinación lineal de los valores pasados de la misma serie.

Se define al término $\phi_p(B)$ de la Ec.(11) como un OPERADOR REGULAR AUTOREGRESIVO de orden p tal que:

$$\phi_p(B) = 1 + \phi_1 B + \phi_2 B^2 + \dots + \phi_p B^p$$

En un modelo AR(p), la función de autocorrelación parcial ρ_k decrece en forma exponencial con el tiempo, en tanto que la función de autocorrelación parcial ρ_{kk} , se "corta" luego del período p.

Modelo de Medias Móviles MA(q)

Desarrollando la Ecuación (10), se tiene:

$$z_t = \mu + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (16)$$

donde se define un OPERADOR REGULAR DE MEDIAS MOVILES DE ORDEN q, tal que:

$$\theta_q(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q, \text{ y}$$

$$1 - \theta(B) = \psi(B)$$

La Ecuación (16) se conoce como la ecuación de un modelo de medias móviles de orden q ó MA(q).

Los modelos MA(q) tienen una función de autocorrelación, ρ_k que se "corta" en el período q, y una función de autocorrelación parcial, ρ_{kk} que decrece exponencialmente; comportamiento éste, opuesto al de los modelos autoregresivos.

Modelos Autoregresivos de Medias Móviles ARMA(p,q).

Los modelos AR(p) y MA(q) pueden agruparse en uno solo, pues se considera que el pronóstico sería más acertado si incluimos el efecto de los valores pasados de la serie y el efecto de los errores pasados. El modelo ARMA(p,q) es entonces de la forma:

$$z_t = \delta + \phi_1 z_{t-1} + \phi_2 z_{t-2} + \dots + \phi_p z_{t-p} - \theta_1 \epsilon_{t-1} - \theta_2 \epsilon_{t-2} - \dots - \theta_q \epsilon_{t-q} + \epsilon_t \quad (17)$$

Las funciones ϕ_k y θ_k de los modelos ARMA(p,q) decrecen exponencialmente.

Modelos ARMA Estacionales

Una cualidad de los modelos de Box & Jenkins que los hace particularmente atractivos para pronóstico, es la posibilidad de representar series estacionales, es decir aquellas que tienen una componente estacional significativa. Si la serie no es estacionaria, se requiere de una transformación que considere el período estacional, para esto, se define un OPERADOR ESTACIONAL DE DIFERENCIACION ∇_L , donde L es el período de la estacionalidad, así:

$$\nabla_L y_t = (1-B^L)y_t = y_t - B^L y_t = y_t - y_{t-L} \quad (18)$$

En forma general, para un número D de diferencias estacionales:

$$\nabla_L^D y_t = (1-B^L)^D y_t \quad (19)$$

Los modelos estacionales tienen las mismas propiedades que los regulares. Se definen dos operadores estacionales: Un OPERADOR ESTACIONAL AUTOREGRESIVO de orden P, tal que:

$$\phi_P(B^L) = (1 - \phi_{1,L} B^L - \phi_{2,L} B^{2L} - \dots - \phi_{P,L} B^{PL})$$

Y un OPERADOR ESTACIONAL DE MEDIAS MOVILES, de orden Q, tal que:

$$\theta_Q(B^L) = (1 + \theta_{1,L} B^L + \theta_{2,L} B^{2L} + \dots + \theta_{Q,L} B^{QL})$$

Modelo General Estacional Multiplicativo

De los modelos regulares y estacionales se puede llegar a definir un modelo completamente general que pueda aplicarse para el pronóstico de cualquier serie de tiempo. Este modelo se conoce como el "Modelo ARMA General Estacional Multiplicativo" y se representa por la ecuación:

$$\phi_P(B) \phi_P(B^L) z_t = \delta + \theta_Q(B) \theta_Q(B^L) \epsilon_t \quad (20)$$

donde z_t es la serie de trabajo definida como:

$$z_t = \nabla^d \nabla_L^D y_t^*$$

y_t^* es la serie original y_t que ha tenido una transformación matemática (logarítmica, cuadrática, etc.).

Es importante observar que el número total de observaciones de una serie y_t , se disminuye cuando se aplica las diferenciaciones, y la serie de trabajo z_t tendrá $(n-(L+d))$ observaciones.

La nomenclatura usada de estos modelos es: $(p,d,q) \times (P,D,Q)_L$. Es posible operar con diferenciaciones estacionales para más de un período L.

SELECCION DEL METODO DE PREDICCION

Para escoger un modelo de predicción se debe considerar los siguientes factores:

- 1) La forma en que se desea pronosticar (puntual o probabilística).
- 2) El intervalo de tiempo que se tomará (plazo de predicción).
- 3) La tendencia de los datos en el pasado.
- 4) El costo del pronóstico. Incluye costos de desarrollo del modelo, almacenamiento de datos y operación.
- 5) La exactitud deseada.
- 6) La disponibilidad de datos.
- 7) La facilidad de operación y comprensión del modelo.

En resumen, el método de predicción que se debe escoger será aquel que satisfaga las necesidades impuestas por la condición para la que fue modelado, al menor costo y con el mínimo de inconvenientes.

APLICACION DE LOS METODOS EN PRONOSTICO DE DEMANDA

El principal objetivo del pronóstico de demanda en la operación de un sistema es obtener una medida más o menos exacta de la demanda eléctrica que ocurrirá en un período futuro, de manera de determinar los requisitos de generación que se debe tener para satisfacer la demanda al mínimo costo de operación.

El pronóstico de la demanda es necesario para la programación del mantenimiento de las unidades generadoras y para despacho económico, como aplicaciones tradicionales; y para control automático de generación, despacho óptimo, soluciones en línea de flujos de carga, como aplicaciones más modernas.

Para pronósticos de largo plazo, es decir aquellos con períodos de medición superiores a un año, se utiliza los métodos de regresión suavizamiento y de descomposición.

En el pronóstico a mediano plazo, los períodos de medición son mensuales, por lo tanto se dispone de un número mayor de datos. Los modelos utilizados son: regresión, alisamiento y descomposición. También se utiliza los modelos ARMA, aunque no es confiable para períodos mayores a 15-20 meses.

Los modelos que se utiliza en corto plazo son: los métodos regresivos que incluyen el efecto de la temperatura y de otros factores atmosféricos, los métodos de análisis espectral, y los modelos ARMA. Los modelos con filtro de Kalman no han tenido aún una aplicación seria.

METODOLOGIA DE BOX & JENKINS

Tan importante como estudiar la teoría en que se basan los modelos de pronóstico, es el procedimiento que se sigue para la obtención de esos modelos. Un proceso sistematizado para analizar y pronosticar series de tiempo ha sido desarrollado por Box & Jenkins, y consiste en cuatro etapas que constituyen la "Metodología de Box & Jenkins".

En la Figura 3 se muestra el procedimiento para analizar las series de tiempo mediante esta metodología.

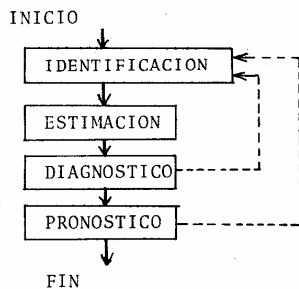


Figura 3 Metodología de Box & Jenkins.

Identificación

En la identificación se debe encontrar los parámetros del modelo $(p,d,q) \times (P,D,Q)_L$. Los pasos para identificar un modelo son:

- 1) Obtener una serie de trabajo.
- 2) Comprobar la estacionaridad de la serie de trabajo y filtrar los datos.
- 3) Analizar las funciones de autocorrelación y de autocorrelación parcial. Si el valor de la estadística "T-Valor" (en inglés: "t-like") es mayor a 2, ρ_k o ρ_{kk} son significativos.
- 4) Determinación de los parámetros p,q,P,Q a usarse en el modelo.
- 5) Selección de modelos tentativos.

Estimación

La estimación de los parámetros p,q,P,Q del modelo se hace por mínimos cuadrados. En este trabajo se ha utilizado un programa

computacional para análisis de series de tiempo que utiliza los modelos de Box & Jenkins. El programa se llama TSERIES, y ha sido mejorado por el autor. Utilizando este programa se calcula los parámetros del modelo. Además, el programa permite aplicar la metodología con facilidad y proporciona una herramienta vital para el pronóstico.

Diagnóstico

La etapa de diagnóstico consiste en probar la exactitud del modelo identificado, y es la parte más importante de la metodología. De ser necesario modificar un modelo identificado, o cuando el error que se obtiene en los parámetros y luego en el pronóstico mismo es significativo, entonces se vuelve a la etapa de identificación de un nuevo modelo que se ajuste mejor a la serie de tiempo. Los pasos para el diagnóstico son:

- 1) Análisis de los estimados de los parámetros del modelo. Importancia de cada parámetro en base a su valor estimado, a su T-valor estadístico, y a su desviación estándar.
- 2) Análisis del error de la serie de residuos. Una vez identificado un modelo, la serie resultante de residuos debe ser ruido blanco. La serie de residuos de un modelo adecuado debe tener:
 - a) La media cercana a cero.
 - b) La varianza pequeña.
 - c) Los residuos máximos y mínimos en un rango aceptable.
 - d) El coeficiente simple de correlación R , cercano a ± 1 .
 - e) El coeficiente múltiple de correlación, R^2 cercano a 1.
 - f) La estadística de Durbin-Watson próxima a 2.
 - g) El pronóstico lo más próximo al valor real.

Una medida de cuán bien se adapta el modelo a los datos de la serie de tiempo, es la estadística de CHI-CUADRADO de Box & Pierce, Q. En general un valor de Q mayor que el que da la curva de CHI-CUADRADO X^2_5 , quiere decir que el modelo es inadecuado. La definición de estos criterios y conceptos estadísticos se los detalla en las referencias citadas en este artículo.

Pronóstico

En la etapa de pronóstico se calcula los valores futuros de la variable de interés, en base a la ecuación de pronóstico obtenida en las etapas anteriores de la metodología.

A continuación se detalla los resultados de tipo práctico que han sido obtenidos al usar los modelos ARMA para pronósticos de la demanda mensual y horaria de la Empresa Eléctrica Quito S.A.

En estos ejemplos se ha utilizado el programa TSERIES para pronóstico que utiliza el método de Box & Jenkins.

PRONOSTICO MENSUAL DE DEMANDA

El primer ejemplo realizado en el estudio de demanda es el pronóstico de la serie de datos mensuales de demanda máxima de potencia en barras de generación de la Empresa Eléctrica Quito. Los datos de la serie van desde enero de 1973 hasta diciembre de 1982, un total de 120 observaciones, las mismas que se muestran en la Tabla A.1 del Apéndice. Luego de hacer un estudio preliminar de la serie para eliminar observaciones no acordes con el comportamiento de la serie, se aplicó la metodología de Box & Jenkins.

Identificación

1) Serie de trabajo y análisis de estacionariedad.
Se probó dos diferencias: una regular de la que se obtuvo la serie de trabajo No. 1, una diferenciación estacional de orden 12, que dio una serie no estacionaria, y una diferenciación regular mas una estacional de orden 12, que dio la serie de trabajo No. 2.

2) Análisis de las funciones muestrales de autocorrelación y de autocorrelación parcial de las series de trabajo.
El gráfico de estas funciones se muestra en la Figura A.1 del Apéndice.

3) Parámetros p,q,P,Q.
En base al análisis de r_k y r_{kk} se probaron varios modelos para cada una de las series de trabajo, obteniéndose seis modelos representativos que modelaron de mejor manera la serie. Los modelos seleccionados se resumen en la Figura 4, donde los tres primeros corresponden a la Serie No. 1 y los tres últimos a la Serie No. 2.

No.	Modelo	Parámetros
1	(2,1,2) X (1,0,1) ₁₂	AR1,AR2,AR12, MA2,MA12
2	(1,1,0) X (1,0,1) ₁₂	AR1,AR12,MA12
3	(1,1,2) X (1,0,1) ₁₂	AR1,AR12,MA2, MA12
4	(2,1,1) X (0,1,1) ₁₂	AR1,AR2,MA1,MA12
5	(2,1,0) X (0,1,1) ₁₂	AR1,AR2,MA12
6	(0,1,1) X (1,1,0) ₁₂	AR12,MA1

Figura 4. Modelos para pronóstico mensual de la EEQA.

Estimación

Para cada uno de los modelos se estimó los parámetros estadísticos necesarios para determinar la bondad de cada modelo, usando el programa TSERIES.

Diagnóstico

Mediante el análisis de los residuos, y luego de un proceso recursivo de afinamiento de los modelos, se seleccionó el Modelo No. 3 como el que representaba en forma más exacta el fenómeno. Las características de este modelo son:

Parámetros estimados: AR1= -0.4789 , AR12=0.9950, MA2=0.3362, MA12= 0.8668

Ecuación de pronóstico:

$$y_t = 0.5211 y_{t-1} + 0.4789 y_{t-2} + 0.9950 y_{t-12} - 0.5185 y_{t-13} - 0.4765 y_{t-14} - 0.3362 e_{t-2} - 0.8668 e_{t-12} + 0.2914 e_{t-14}$$

Pronóstico

Para el Modelo No. 3 seleccionado, se hizo el pronóstico de los 12 meses últimos, correspondientes al año 1982, y se obtuvo los siguientes errores estadísticos:

Media del error: 1,68 MW (0.96 %)
Desviación estándar del error: 1,57 MW (0.89%)

Estos resultados del pronóstico de 1982 se presentan en forma gráfica en la Figura A.2 del Apéndice.

El pronóstico del año 1983 se hizo utilizando el Modelo No. 3 y se obtuvo errores mínimos para los doce meses del año. Los resultados se presentan en la Figura 5, donde se puede apreciar que el error porcentual medio es de 1.65 %, lo que demuestra la exactitud del modelo. Además, la demanda máxima del año en el mes de diciembre pronosticada, coincide exactamente con el valor real.

MES	DEMANDA		ERROR	
	real	pronóstico	MW	%
Enero	180.10	182.31	2.21	1.23
Febrero	180.00	183.64	3.64	2.02
Marzo	183.30	185.98	2.68	1.46
Abril	183.90	185.21	1.31	0.71
Mayo	187.30	186.90	0.40	0.21
Junio	183.40	187.96	4.56	2.49
Julio	183.50	185.89	2.39	1.30
Agosto	179.80	183.06	3.26	1.81
Septiembre	178.80	185.93	7.13	3.99
Octubre	184.90	190.63	5.73	3.10
Noviembre	189.70	192.40	2.70	1.42
Diciembre	194.10	194.19	0.09	0.05

Figura 5. Error en el pronóstico mensual usando el Modelo No. 3, año 1983.

PRONOSTICO HORARIO DE DEMANDA

Si bien en el pronóstico mensual, los resultados demostraron la bondad de los modelos ARMA, la base matemática de estos métodos los hace de particular interés para series con gran número de observaciones, como es el caso del pronóstico horario.

Serie de Datos

La serie de datos de demanda máxima de potencia de generación en MW, de la Empresa Eléctrica Quito S.A. la constituye un total de 1344 observaciones, o sea de 8 semanas de mediciones hora a hora. Los días medidos van desde el Lunes 28 de febrero de 1983 hasta el Domingo 15 de mayo de 1983. La serie solo toma en cuenta los días NORMALES, es decir aquellos donde el comportamiento de la demanda es comparativamente similar y explicable. Se excluyeron de la serie los días anormales, que corresponden a las semanas del 31 de marzo al 6 de abril en que hubo una huelga nacional, y a la del 1 de mayo

al 7 de mayo, por fiesta cívica el 1 de mayo lo que obligó a descartar la semana entera.

Suposiciones

El análisis de la serie de demanda horaria asume que:

- 1) Los días son normales.
- 2) No hay factores ajenos a la demanda.
- 3) Los datos medidos son coincidentes.
- 4) La serie puede ser descompuesta en series menores sin desmedro de las características propias de la serie original total.

Procedimiento Seguido

- 1) Se filtró los datos y se obtuvo una serie de trabajo mediante la diferenciación de la serie original.
- 2) Se dividió la serie en series menores: a) de los días lunes, b) de los días martes a jueves, c) de los días viernes, d) de los días sábado, y e) de los días domingo. Cada una de estas series fue analizada individualmente para luego hacer el pronóstico en forma separada.
- 3) Se comprobó la bondad de los modelos de cada serie mediante un pronóstico de las cinco semanas posteriores. Se comparó dos alternativas, la una que considera que los parámetros del modelo seleccionado son estimados con cada nuevo período de observaciones (Método de Parámetros Estimados, MPE), y la otra que toma los parámetros originales para los pronósticos siguientes, sin modificarlos (Método de Parámetros Fijos, MPF).
- 4) Se comparó los resultados usando los métodos de parámetros fijos y parámetros estimados para cada serie.
- 5) Finalmente, se comparó la exactitud de los métodos MPF y MPE con el método tradicional de pronóstico.

Metodología de Box & Jenkins

La serie original con 1344 observaciones fue modelada al principio en forma total, pero la identificación se tornó difícil tanto por el tiempo de proceso en el programa, como por la imposibilidad de encontrar parámetros significativos. El modelo total tenía más de 30 parámetros. En vista de que el comportamiento de la demanda es muy diferenciado para cada día de la semana, se vio conveniente dividir la serie total en series más pequeñas agrupando los días iguales uno a continuación del otro para formar las cinco series de trabajo. Los resultados obtenidos han comprobado esta selección.

En la Tabla A.2 del Apéndice se resume los resultados de los modelos de demanda horaria. La Tabla A.3 presenta las ecuaciones de pronóstico de los modelos seleccionados para cada una de las series. Para la obtención de estos modelos se realizaron varias corridas en el programa TSERIES hasta encontrar los parámetros que ajusten mejor los datos. Si bien los modelos obtenidos han demostrado ser bastante exactos, para efectos de ser aplicados en el despacho diario, y dependiendo del sistema de potencia, cada sistema deberá tener un modelo de acuerdo a sus características propias.

Con las ecuaciones de pronóstico obtenidas del diagnóstico, se procedió a hacer el pro-

nóstico del siguiente período, es decir la curva de carga diaria de cada serie, como la mostrada en la Figura A.4 del Apéndice, para la serie de los días Lunes.

Pruebas de los Modelos de Cada Serie

Luego de seleccionar los modelos de cada serie, se probaron en el pronóstico de cinco períodos futuros normales. Los datos de estos períodos no fueron tratados, lo que representaba una situación pesimista.

Se utilizó dos métodos, el de parámetros fijos y el de parámetros estimados. Los errores del pronóstico para cada uno de estos métodos se presentan en la Tabla A.5.

Comparación con el Método Tradicional

Una vez que se finalizó el estudio del pronóstico horario usando los modelos ARMA, era de interés poder comparar los resultados con los que se obtienen en la forma tradicional de pronóstico que se utiliza para el despacho de carga en INECEL. Este método consiste en tomar las mediciones del día de la semana anterior al que se va a hacer el pronóstico. Se analiza situaciones especiales de la carga para ese día, detallando las causas de tales variaciones. Luego se rectifica estas mediciones de acuerdo a valores más reales dados por la experiencia de la persona que hace el pronóstico. Finalmente, el conjunto de mediciones pasadas rectificadas son el pronóstico futuro. Este método proporciona un solo valor (pronóstico puntual), no toma en cuenta la historia de la serie, y no tiene una base matemática. Los errores del método tradicional se presenta en la Tabla A.4. Se comparó los resultados de las cinco series utilizando los métodos MPF, MPE y tradicional. Estos resultados se presentan en la Tabla A.6. Los resultados son muy favorables para el método de Box & Jenkins, pues a pesar de que aparentemente el método tradicional proporcione un error menor, el método de Box & Jenkins sin considerar el factor de participación humana para hacer el pronóstico, se aproxima bastante al método tradicional, además de que nos da un pronóstico probabilístico. El MPE es más exacto, como era de suponer, que el MPF, por ser un modelo quasi-adaptivo.

Comentarios al Pronóstico Horario

El estudio de pronóstico usando el método de Box & Jenkins ha demostrado su efectividad, y se puede tener la seguridad de que su uso en otros sistemas de potencia tendrá también el éxito que se ha obtenido en el sistema de la Empresa Eléctrica Quito.

Al parecer, solamente son necesarias dos diferencias para transformar la serie original en una serie de trabajo estacionaria, una regular y una estacional de orden 24. En casi todas las series hay un término AR1, un término MA1 y un término estacional MA24, sumándose otro término AR de orden 20 a 25.

El método de parámetros fijos es más conveniente que el de parámetros estimados, ya que el ahorro en tiempo de proceso de computador y de análisis de los resultados, compensa la pequeña diferencia en el error entre ambos métodos. Se podría estimar los parámetros una vez cada mes, con lo que se conciliaría ambos métodos.

CONCLUSIONES

El estudio de los métodos de pronóstico es de gran importancia en la planificación y en la operación de un sistema eléctrico. En este trabajo se ha presentado varios modelos de pronóstico horario de un sistema eléctrico en particular, pudiendo el mismo ser aplicado en otros sistemas.

Los errores obtenidos con el método de Box & Jenkins son del 1% en pronóstico mensual, y del 3% al 4% en pronóstico horario, para el ejemplo de la Empresa Eléctrica Quito. Al parecer, este método podría ser muy efectivo

para el pronóstico de demanda en tiempo real.

Los datos históricos de la demanda deben necesariamente ser tratados, tanto al inicio del proceso de modelación, como al final del mismo, de modo que el hombre intervenga directamente en forma crítica con su experiencia para obtener los resultados más acertados.

El método de pronóstico que se debe escoger será aquel que satisfaga las necesidades impuestas por la condición para la que fue modelado, al menor costo y con el mínimo de inconvenientes.

APENDICE

C DATOS DE POTENCIA DE LA EEQ DESDE ENERO DE 1973												
DATA	READ 120 OBSERVACIONES											
C	ENE	FEB	MAR	ABR	MAY	JUN	JUL	AGO	SEP	OCT	NOV	DIC
66.2	66.6	67.9	68.8	69.6	70.5	70.5	68.2	69.6	71.5	72.8	76.6	
75.3	73.2	73.3	80.0	77.3	81.7	81.0	76.6	73.9	84.2	84.6	85.1	
83.8	86.8	88.2	88.7	90.4	89.1	89.6	88.6	89.2	95.9	98.3	99.1	
96.3	99.0	98.0	98.0	98.3	96.8	94.3	98.2	97.9	102.9	107.4	110.4	
108.0	110.6	117.4	114.4	118.4	118.2	115.9	117.1	120.3	124.0	124.8	126.7	
126.1	130.1	133.9	129.1	131.5	129.7	123.4	126.8	127.3	131.7	134.4	134.1	
135.7	136.6	139.5	135.9	139.7	138.6	138.6	133.4	139.5	144.2	147.5	148.2	
143.3	147.7	150.4	156.9	156.2	158.3	151.0	149.3	151.5	153.8	160.4	161.3	
163.8	163.6	159.3	160.4	160.6	163.5	165.5	157.0	162.6	167.7	169.2	171.2	
169.5	170.6	177.3	174.1	175.1	180.5	174.9	167.9	174.4	178.9	179.4	183.6	
IBEN												
STOP												

Tabla A.1. Datos de potencia mensual de la Empresa Eléctrica Quito, para el pronóstico mensual.




Figura A.1. Serie original y series de trabajo para el pronóstico mensual




Figura A.2. Salida del programa TSERIES para el pronóstico mensual del año 1982




Figura A.3. Salida del programa TSERIES para el pronóstico mensual del año 1983

SERIE	Parámetros	Valor	Error Estándar	T-valor	Límite 95% Conf.		Suma de Cuadrados	Iteraciones
					Mínimo	Máximo		
HLUN	AR 1	0.3048	0.0917	4.1976	0.2051	0.5645	2163.20	16
	MA 1	0.9031	0.0385	23.4479	0.8276	0.9786		
	MA 24	0.8408	0.0723	11.6234	0.6991	0.9826		
HVAR - JUE	AR 1	0.3647	0.0556	6.5622	0.2557	0.4736	8700.79	22
	AR 25	0.1056	0.0029	36.6958	0.0999	0.1112		
	MA 1	0.8346	0.0254	32.9161	0.7349	0.8644		
	MA 3	0.0800	0.0029	27.2655	0.0743	0.0858		
HVIIE	AR 1	0.1867	0.1990	0.9380	-0.2034	0.5768	1787.50	16
	MA 1	0.5324	0.1947	2.7339	0.1506	0.9141		
	MA 2	0.2735	0.1367	2.0007	0.0055	0.5413		
	MA 24	0.8076	0.0754	10.7042	0.6597	0.9555		
HSAB	AR 1	0.4945	0.0751	6.5345	0.3472	0.6417	2256.07	21
	AR 25	-0.1538	0.0693	-2.2194	-0.2857	-0.0180		
	MA 1	0.9465	0.0268	35.3485	0.8940	0.9989		
	MA 24	0.8131	0.0733	11.0397	0.6694	0.9569		
HDOX	AR 1	0.5701	0.1043	5.4639	0.3655	0.7746	1784.81	20
	AR 20	-0.1731	0.0680	-2.5436	-0.3065	-0.0397		
	MA 1	0.8567	0.0737	11.6260	0.7122	1.0011		
	MA 24	0.8481	0.0686	12.3588	0.7136	0.9826		

Tabla A.2
Resultados de los modelos de pronóstico horario

Tabla A.3

Ecuaciones de pronóstico para los modelos de pronóstico horario

SERIE	Ecuación de Pronóstico
HLUN	$\hat{y}_t = 1.3848 y_{t-1} - 0.3848 y_{t-2} + y_{t-24} - 1.3848 y_{t-25} + 0.3848 y_{t-26} - 0.9031 \epsilon_{t-1} - 0.8408 \epsilon_{t-24} + 0.7593 \epsilon_{t-25}$
HVAR - JUE	$\hat{y}_t = 1.3647 y_{t-1} - 0.3647 y_{t-2} + y_{t-24} - 1.2591 y_{t-25} + 0.2591 y_{t-26} - 0.1056 y_{t-49} + 0.1056 y_{t-50} - 0.8346 y_{t-1} - 0.0800 \epsilon_{t-3} - 0.9432 \epsilon_{t-24} + 0.7873 \epsilon_{t-25} + 0.0755 \epsilon_{t-27}$
HVIIE	$\hat{y}_t = 1.1867 y_{t-1} - 0.1867 y_{t-2} + y_{t-24} - 1.1867 y_{t-25} + 0.1867 y_{t-26} - 0.5324 \epsilon_{t-1} - 0.2735 \epsilon_{t-2} - 0.8076 \epsilon_{t-24} + 0.4299 \epsilon_{t-25} + 0.2209 \epsilon_{t-26}$
HSAB	$\hat{y}_t = 1.4945 y_{t-1} - 0.4945 y_{t-2} + y_{t-24} - 1.6483 y_{t-25} + 0.6483 y_{t-26} + 0.1538 y_{t-49} - 0.1538 y_{t-50} - 0.9465 \epsilon_{t-1} - 0.8131 \epsilon_{t-24} + 0.7696 \epsilon_{t-25}$
HDOX	$\hat{y}_t = 1.5701 y_{t-1} - 0.5701 y_{t-2} - 0.1731 y_{t-20} + 0.1731 y_{t-21} + y_{t-24} - 1.5701 y_{t-25} + 0.5701 y_{t-26} + 0.1731 y_{t-44} - 0.1731 y_{t-45} - 0.8567 \epsilon_{t-1} - 0.8481 \epsilon_{t-24} + 0.7265 \epsilon_{t-25}$




Figura A.4. Salida del programa TSERIES para la serie HLUN de pronóstico horario

	ERROR		DESVIACION ESTANDAR	
	(M%)	(%)	(M%)	(%)
LUNES	4.04	3.58	3.04	2.65
MARTES	5.04	4.16	3.54	3.24
MUECOLES	3.58	3.26	3.15	3.03
JUEVES	3.26	2.68	3.08	2.33
VIERNES	3.66	2.84	3.34	2.54
SABADO	5.02	5.26	4.49	4.56
DOMINGO	4.08	4.86	3.65	4.32

Tabla A.4. Errores en el pronóstico horario usando el método tradicional.

	ERROR (M%)			ERROR (%)		
	Parametros Fijos	Parametros Estimados	Tradicional	Parametros Fijos	Parametros Estimados	Tradicional
LUNES	5.68	5.48	4.04	5.08	4.88	3.58
MARTES-JUEVES	4.77	4.20	3.96	4.08	3.62	3.27
VIERNES	3.16	3.49	3.66	2.87	2.89	2.84
SABADO	5.83	5.37	5.02	6.19	5.71	5.26
DOMINGO	3.32	3.15	4.08	4.07	3.81	4.86
PRONMEDIO	4.55	4.34	4.15	4.46	4.18	3.96

Tabla A.6. Comparación con el método tradicional de pronóstico

FUNCIONES DE AUTOCORRELACION Y DE AUTOCORRELACION PARCIAL

1.- Función muestral de autocorrelación

$$r_k = \frac{\sum_{t=a}^{n-k} (z_t - \bar{z})(z_{t+k} - \bar{z})}{\sum_{t=a}^{n-k} (z_t - \bar{z})^2} \quad k = 1, 2, \dots$$

donde: a es el origen de la serie, ó primera medición,
 \bar{z} es la media de las observaciones,
 k_i son los períodos de las observaciones.

SERIE	PRONOSTICO PASADO								PRONOSTICO FUTURO							
	PARAMETROS FIJOS				PARAMETROS ESTIMADOS				PARAMETROS FIJOS				PARAMETROS ESTIMADOS			
	MW	Z	MW	Z	MW	Z	MW	Z	MW	Z	MW	Z	MW	Z		
Lunes	3.49	0.45	3.15	0.47	3.33	0.38	2.97	0.45	5.68	2.51	5.08	2.33	5.48	2.65	4.88	2.33
Martes a Jueves	4.97	1.15	4.33	0.94	4.61	0.60	4.03	0.54	4.77	0.65	4.08	0.44	4.20	0.19	3.62	0.14
Viernes	3.47	1.21	2.99	0.88	3.59	1.35	3.02	1.02	3.46	0.92	2.87	0.78	3.49	0.87	2.89	0.75
Sábado	4.18	1.04	4.43	1.27	3.66	0.61	3.80	0.72	5.83	1.40	6.19	1.56	5.37	1.22	5.71	1.23
Domingo	3.04	1.04	3.71	1.49	3.07	1.06	3.73	1.52	3.32	0.74	4.07	1.10	3.15	0.98	3.81	1.23
PRONMEDIO	3.83	0.98	3.72	1.01	3.65	0.80	3.51	0.85	4.61	1.24	4.46	1.24	4.34	1.16	4.18	1.15



Tabla A.5. Comparación de los errores para los modelos de pronóstico horario MPF y MPE

2.- Función muestral del autorrelación parcial.

$$r_{jk} = \begin{cases} r_1 & \text{si } k = 1 \\ r_k - \sum_{j=1}^{k-1} r_{k-1,j} r_{k-j} & \text{si } k = 2, 3, \dots \end{cases}$$

donde: $r_{j,j} = r_{k-1,j} - r_{j,k} r_{k-1,k-j}$ para $j = 1, 2, \dots, k-1$

GRAFICO DE LAS FUNCIONES DE AUTOCORRELACION Y DE AUTOCORRELACION PARCIAL MODELOS ARMA



BIBLIOGRAFIA

Anderson, O. D., Time Series Analysis and Forecasting - The Box & Jenkins Approach, London and Boston, Butterworths, 1976.

Box, G. E. P., Jenkins, G. M., Time Series Analysis, Forecasting and Control, San Francisco, Holden-Day, 1970.

Bowerman, Bruce L.; O'Connell, Richard T., Time Series Analysis and Forecasting, Massachusetts, Duxbury Press, 1979

Brown, O., "Random Signals & Noise", EE521 Class Notes, Iowa State University, Ames, Iowa, USA., 1982.

Galiana, F. D., "Short-Term Load Forecasting", Systems Engineering For Power Status and Prospects, Henniker, N. H., Aug 17-22, 1975.

Irisarri, G. D.; et. al., "On-Line Load Forecasting for Energy Control Center Application", IEEE TPAS, January 1982, pp. 71-79.

Keyhani, A.; Miri, S. M., "On-Line Weather-Sensitive and Industrial Group Bus Load Forecasting for Microprocessor Based Applications", IEEE, PICA 83, pp. 63-71.

Makridakis, Spyros; Wheelwright, Steven C., Forecasting Methods and Applications, New York, John & Sons, 1978.

Meeker, William Q., TSERIES, A User Oriented Computer Program for Identifying, Fitting and Forecasting ARIMA Time Series Models, USER'S MANUAL, Statistical Laboratory, Iowa State University, Ames, Iowa, USA., 1977.

Morettin, Pedro Alberto; De Castro Toloi, Clélia Maria, Modelos para Previsão de Séries Temporais, Vol. 1, Rio de Janeiro, Instituto de Matemática Pura e Aplicada, 1981.

Ross, D. W.; et. al., "Short-Term Load Prediction for Economic Dispatch of Generation", IEEE PICA-79 Proc., May 15-18, 1979, pp. 198-204.

Ruiz, M.; et al., "Pronóstico de Carga a Corto Plazo en Días Anormales", Instituto de Investigaciones Eléctricas, México, IEEE MEXICON - 81, 1981, pp. 275-280.

Sterling, M. J. H., Power System Control, England, Peter Peregrinus, 1978.

SANCHEZ MIÑO, SANTIAGO



Nació en Quito, Ecuador el 16 de Septiembre de 1956. Obtuvo el título de Ingeniero Eléctrico en la Escuela Politécnica Nacional de Quito, en Agosto de 1980 y el título de Master of Electrical Engineering en Iowa State University, Ames, EE.UU., en Mayo de 1982.

Este trabajo fue realizado mientras trabajaba en INECEL, en el Centro Nacional de Control de Energía. Actualmente trabaja en el Fondo Nacional de Preinversión. Es miembro del CIEEPI y del IEEE.