



SISTEMA DE PREDICCIÓN DE LA DEMANDA DE GAS NATURAL BASADO EN LA APLICACIÓN DE INTELIGENCIA ARTIFICIAL Y REDES NEURONALES

**Autores: Jose Maria Sanfeliu
Jorge Doumanian**

Empresa: GasNatural BAN

RESUMEN EJECUTIVO:

La industria del gas en la Argentina se mueve en un marco de acceso abierto que impone entre otras, las necesidades de efectuar programaciones y nominaciones diarias de gas y transporte conforme a lo establecido en las Pautas para el manejo de los Despachos de gas vigentes.

Es en este marco y a los efectos de realizar las programaciones diarias, que gasNatural BAN ha desarrollado un sistema de predicción de la demanda de gas, el cual por sus características se presenta como único en su tipo en la industria del gas.

Su funcionamiento permite predecir la demanda diaria a través de una serie de datos de partida tales como temperaturas y humedad previstas, tipo de día (hábil, festivo), etc.

A tal efecto utiliza una metodología basada en la aplicación de redes neuronales e inteligencia artificial que predicen los futuros consumos de gas de manera dinámica, conforme la evolución de las tendencias actuales de consumo, e incorporando el conocimiento a priori existente.

Una serie de mecanismos de filtrado de estos datos y el análisis de la historia que el sistema guarda en su memoria le permiten distinguir entornos de comportamientos similares al planteado para la realización de la predicción.

La aplicación se ha desarrollado en un entorno Windows, que permite la presentación de todas sus entradas y salidas a través de herramientas de microinformática de uso standard.

Otra característica distintiva del sistema es que trabaja de manera absolutamente integrada con el resto de las aplicaciones que se utilizan en el Control de la Explotación lo que facilita el manejo de datos en tiempo real a través del Sistema SCADA que opera la compañía y de las estaciones meteorológicas propias.

En síntesis, se ha conseguido un producto de avanzada, que permite a la empresa disponer de una herramienta de tecnología de punta y ponerse a la vanguardia en la utilización de un desarrollo informático único en la industria del gas.

1. DESCRIPCION DEL SISTEMA GASIFERO ARGENTINO.

1.1 Generalidades:

La República Argentina tiene una superficie de 3.794.264 km² en la que habitan 32 millones de habitantes distribuidos en 23 provincias.

La participación del gas en la matriz energética argentina es del 42 %, existiendo en el país un total de 5,7 millones de clientes con un consumo anual de 20.000 Mm³/año, de los cuales 1.180.000 son abastecidos por **gasNatural BAN** con un consumo anual de 2.500 Mm³/año.

El abastecimiento de gas se realiza a través de la producción de las tres cuencas que existen en el país (Neuquina, Austral y Norte), a las que hay que añadir las importaciones de gas de Bolivia.

El gas se transporta a los centros de consumo mediante cinco sistemas de gasoductos operados por dos transportistas, Transportadora de Gas del Sur (TGS) y Transportadora de Gas del Norte (TGN), los cuales entregan el gas a las nueve distribuidoras y a los clientes directos con los que tengan contratos.

1.2 Características del Sistema Gasífero Argentino.

La demanda está concentrada en la Capital Federal y Gran Buenos Aires, 37% del pico diario invernal, que en 1999 fue de 107 Mm³/día.

Las cuencas productivas están ubicadas en los extremos Norte, Sur y Centro Oeste del país, y por tanto muy alejadas de la zona de máximo consumo.

Las capacidades de producción y transporte son insuficientes para cubrir la totalidad de la demanda durante un día pico de invierno, estimándose que la demanda insatisfecha puede ser del orden de 10 Mm³/día.

No se dispone de suficientes almacenamientos (**solo la Planta de Peak Shaving de Gas Natural BAN**) que permitan aportar gas al sistema durante los días de máxima demanda.

Es un sistema de acceso abierto con la producción desregulada, lo cual implica un número creciente de productores y la posibilidad de que los clientes establezcan directamente sus contratos de compra y/o transporte.

1.3 Situación del Sistema de Gas Natural BAN.

En el contexto del marco señalado, **Gas Natural BAN** es (de las 9 existentes) la distribuidora que tiene a su cargo el brindar el servicio en forma exclusiva en 26 partidos del conurbano de la Capital Federal en la Provincia de Buenos Aires.

El área de distribución comprende 15.000 km², más de 1.200 km. de redes de alta presión, 18.000 km. de redes de media presión y es habitada por unos 6.000.000 de habitantes de los cuales, como ya se ha adelantado, se sirve a unos 1.180.000 clientes en el área doméstico-comercial y se provee de gas a unos 1100 establecimientos industriales.

Posee además una Planta de Peak Shaving con capacidad de almacenamiento de 25Mm³, y una capacidad diaria de emisión de 2,5Mm³/día.

La demanda de gas en la zona servida por la compañía presenta una marcada característica de estacionalidad, con valores máximos del orden de los 15Mm³/día en la punta invernal con una componente ininterrumpible del orden de los 14Mm³/día y valores mínimos del orden de los 4Mm³/día en el período estival.

1.4 Problemática de la operación del Sistema.

El sistema descrito presenta una problemática con los siguientes aspectos fundamentales a resolver.

- a) **Demanda insatisfecha**, básicamente centrada en los clientes industriales con contratos interrumpibles.
- b) **Sistema de transporte caracterizado por la falta de flexibilidad**, con la consecuente necesidad de que el consumo real se asemeje lo más posible al estimado en el proceso previo de predicción de la demanda realizada sobre base diaria.
- c) **Impacto económico** que implica el gestionar un sistema cuyo factor de utilización de la capacidad de transporte firme contratada es bajo, e impone un costo anual de U\$S 6.800.000 por cada millón de m³ contratados.

1.5 Gestión del Sistema.

Así pues, y para gestionar adecuadamente un sistema abierto de estas características y con la problemática presentada es preciso disponer de una serie de herramientas de gestión, a saber:

* **Pautas de Despacho** comunes para todo el sector, que permitan coordinar la carga, el transporte y la entrega de gas en los puntos de consumo, de modo que se garanticen el equilibrio en el balance global del sistema y las presiones necesarias para asegurar el suministro a los clientes firmes.

El mismo se fundamenta en un sistema de control de desbalances acumulados de inventario de cada cargador en el sistema de transporte, de modo de mantener a los mismos dentro de las bandas de tolerancia establecidas.

A efectos de la explotación del sistema de distribución, gasNatural BAN ha montado un Despacho de Gas que posee un Sistema SCADA de monitoreo y control y funciona las 24 horas los 365 días del año, y que permite entre otras cosas monitorear en tiempo real el 98% de las cantidades de gas que ingresan y egresan del sistema.

***Capacidad de Transporte** suficiente para cubrir la demanda firme de cada Distribuidora y de cada cliente directo.

*** Programas de reducción de consumo a los clientes interrumpibles** basados en el principio de la no discriminación, de modo que se pueda ajustar la demanda a las capacidades de transporte contratadas de modo que se equilibre el sistema.

En orden al cumplimiento de estos programas, gasNatural BAN ha desarrollado un Sistema de control de consumos de clientes industriales que permite monitorear en forma horaria los consumos de los principales clientes con consumos firmes e interrumpibles.

***Mecanismos de "Peak Shaving"**, ya sea a través de la Planta de Almacenamiento Criogénico que opera la compañía en Gral. Rodríguez o a través de acuerdos entre los distintos cargadores, que permitan balancear el sistema optimizando la estructura de costes de transporte de las compañías.

*** Sistemas de predicción de la demanda diaria**, basados en las previsiones meteorológicas y en los datos históricos de consumo, y que permitan reprogramar las necesidades diarias en base a los datos reales del día en curso.

Para el cumplimiento de este objetivo, en el año 1994 se inicio la implementación de un **Sistema de Predicción de la Demanda de Gas**, sustentado en la utilización de redes neuronales el cual es motivo de esta presentación.

2. SISTEMA DE PREDICCIÓN DE LA DEMANDA DE GAS EN GAS NATURAL BAN

2.1. Antecedentes:

En el inicio de las operaciones de la compañía, la predicción de la demanda estaba en manos de expertos que utilizaban información disponible sobre parámetros relevantes asociados a la red de distribución y al consumo.

Antes de la implantación de un mecanismo automatizado de previsión, el consumo de gas se estimaba utilizando un modelo lineal que descomponía el consumo en la componente industrial y la residencial.

El consumo industrial se consideraba dependiente del tipo de día (Laborable, Feriado, Festivo) y se estimaba a partir de datos históricos. Las variaciones observadas se ajustaban manualmente en función de la tendencia de la demanda en los consumidores industriales.

Por otro lado el consumo residencial se consideraba lineal con la temperatura. Los parámetros de ajuste se actualizaban manualmente en función de la tendencia de los días anteriores. Pese a la simplicidad del modelo, los resultados eran aceptables (No poseemos registro histórico de las previsiones hechas con anterioridad a la implantación del modelo



automático, por lo que no nos es posible cuantificar los valores del error de previsión) para días con comportamiento normal, aunque a costa de una fuerte intervención por parte del experto en la manipulación de los parámetros del modelo.

Esta situación se vio modificada por una serie de razones a saber:

- Creaba una dependencia respecto de personas específicas con un conocimiento difícil de transmitir.
- Irrupción del desarrollo tecnológico en el campo informático adecuándose a las necesidades cada vez más competitivas de la industria.
- Condiciones de exigencia como las descriptas en la problemática de operación del sistema argentino.

Estos hechos generaron la necesidad de modelizar la demanda mediante algoritmos de naturaleza cuantitativa basados en series históricas. A partir de los mismos se ha intentado proyectar la evolución futura de la demanda sirviendo de herramienta a los expertos en sus predicciones.

Para evitar el fuerte componente “manual” del anterior mecanismo de previsión, haciéndolo más sistemático y robusto ante días de comportamiento anómalo se aborda la implementación de un sistema automatizado de previsión al que llamamos “**SANDRA**”

2.2 Desarrollo del proyecto para la construcción del Sistema de Aprendizaje Neuronal de la Demanda con Reglas de Autocorrección “SANDRA”

2.2.1. Análisis Inicial

En esta etapa se realizaron los estudios iniciales a efectos de determinar los objetivos del proyecto y de definir las especificaciones funcionales.

2.2.2. Objetivos del proyecto

- a) Realizar la previsión de la demanda de gas diaria a través de una herramienta tecnológica que permitiera programar las cantidades de gas y transporte a requerirse para el día operativo siguiente y dos días posteriores a través de la utilización de:
 - valores históricos de consumo
 - serie de temperaturas y humedad históricas
 - caracterización del tipo de día a predecir (laborable o festivo)
- b) Conseguir predicciones de consumo lo más cercanas a la realidad a efectos de cumplimentar las exigencias establecidas en el marco que regula la actividad de la industria en la Argentina, y optimizar la operación.

- c) Desarrollar un módulo de predicción de la demanda horaria a efectos de poder realizar ajustes durante el día operativo en curso.
- d) Disponer de una herramienta de soporte para la planificación de los consumos de gas y transporte a mediano y largo plazo.

2.2.3. Elaboración de Especificaciones Funcionales

A partir de la definición de los alcances se elaboraron los documentos de especificaciones funcionales que definieron las pautas, plazos, metodología y alcances del desarrollo del proyecto.

Mención aparte merece las características requeridas a la metodología aplicada en el desarrollo del proyecto, a saber:

Objetiva (Pero intervenible): Las previsiones deben ser reproducibles, aunque modificables por el Experto.

Robusta: El sistema debería funcionar en situaciones donde exista falta de información o esta sea incorrecta.

Fiable: El error cometido deberá ser el mínimo posible.

2.2.4. Construcción de la Base de Datos

A partir de la base de datos de las variables de entorno, así como las variables asociadas al problema, se elaboraron las estructuras de datos para el análisis, la predicción y la evaluación de la predicción.

El programa trabaja con una base de datos asociada de la que obtiene la información necesaria para la predicción diaria y horaria. La misma contiene:

- Temperaturas máximas y mínimas diarias históricas del área de servicio
- Humedades máximas y mínimas diarias históricas del área de servicio
- Consumos históricos diarios y horarios reales por puntos de recepción
- Consumos históricos diarios y horarios reales totales
- Día de la semana y tipo de día (festivo, laborable)
- Temperaturas máximas y mínimas diarias y horarias pronosticadas
- Humedades máximas y mínimas diarias pronosticadas

2.2.5. Investigación de Metodología

En esta tarea se analizaron la metodología de cálculo y predicción que a continuación se describen someramente.

2.2.5.1. Modelos de Auto-Regresión (ARIMA)

Utilizados para predicción en series temporales que emplean variables asociadas a los parámetros relevantes al modelo así como parámetros que generan distorsión en la serie temporal de la demanda.

La ecuación básica del modelo se centra en algoritmos que describen un ciclo temporal en función de la variable a predecir, la que es corregida por polinomios en función de condiciones de laboralidad y meteorológicas, y de disturbios estacionales.

Ejemplo:

$$\ln D_d = \ln D_{d-1} + (\ln D_{d-7} - \ln D_{d-8}) + f_1(\text{wor}_d) + f_2(\text{wea}_d) + w_d$$

D_d = Demanda para el día d

D_{d-n} = Demanda para el día $d - n$

$f_1(\text{wor}_d)$ = Polinómica de corrección por laboralidad

$f_2(\text{wea}_d)$ = Polinómica de corrección por factor meteorológico

w_t = disturbio estacional

Los factores wor y wea pueden agruparse en dos grandes conjuntos:

wor - Condiciones de Laboralidad

Días festivos intersemanales y generales, período de vacaciones (Pascua, Navidad, Verano), acontecimientos especiales (Elecciones, huelga, cambios de horario), carácter de la fiesta (Nacional, local), movilidad calendario (Semana Santa), caída del nivel de actividad (Navidad y Agosto)

wea - Condiciones Meteorológicas

Temperaturas (Máxima, Mínima y Dispersión) de la zona geográfica, los efectos acumulativos generados por las inercias termicas de los días anteriores y los hábitos de los clientes, la saturación del consumo individual (Por mas que baje la temperatura sí ya están encendidos los aparatos calefacción no aumentará el consumo), las estaciones climáticas, el nivel de equipamiento de calefacción

De la aplicación de los métodos de Autoregresión (ARIMA) se obtuvieron las siguientes conclusiones:

- Buenos resultados a corto alcance
- Necesidad de mantenimiento frecuente
- Dificultad de incorporación del conocimiento a priori



2.2.5.2. Modelos de Regresión dinámica - Utilización de inteligencia artificial

El objeto principal de la Inteligencia Artificial es la simulación en medios mecánicos del comportamiento humano, que en sí mismo implica un proceso de constante y progresiva mejora de la actividad desarrollada, caracterizando de esta manera el concepto de aprendizaje.

Los desarrollos que se soportan en técnicas de aprendizaje mecánico a través de inteligencia artificial, han desarrollado sistemas que automodifican progresivamente su comportamiento tratando de hacerlo mas adecuado a las tareas propuestas.

Esta modificación del comportamiento puede hacerse en base a las sugerencias de algún elemento externo al programa o mediante criterios puramente internos de optimización respecto de los objetivos a cubrir. En el primer caso se habla de aprendizaje supervisado, mientras que en el segundo los procesos involucrados se incluyen normalmente dentro de la categoría de aprendizaje no supervisado.

2.2.5.3. Aprendizaje supervisado - Redes Neuronales

Un diseño frecuentemente adoptado en sistemas que exhiben comportamiento de aprendizaje es el de una red neuronal.

Una red neuronal consta de Unidades (Neuronas) como elementos de proceso con interconexiones (Sinapsis), que contienen un número real asociado como peso de su relevancia y actividad. Cada unidad recibe un determinado número como input y genera otro como output.

Finalizado el proceso de aprendizaje la red debe ser capaz no sólo de reproducir con éxito las situaciones que le han sido mostradas en el conjunto de aprendizaje, sino que, por proximidad, deberá generar respuestas “razonables”, incluso en situaciones de input no previstas en el conjunto de entrenamiento.

La situación mencionada es un ejemplo paradigmático de la metodología propia del Aprendizaje Supervisado.

El elemento externo, “supervisor” o “profesor” es el que proporciona las respuestas adecuadas que dirigen el proceso de aprendizaje.

La modificación progresiva de las interconexiones de la red hacia sus valores óptimos constituye un buen ejemplo de automodificación del proceso, propia de todo sistema de aprendizaje.

La posibilidad final de respuesta razonable de la red en situaciones para las que no ha sido entrenada, constituye un ejemplo de su capacidad de generalización y forma parte de las características deseables en cualquier sistema de aprendizaje.

De la aplicación de métodos de Redes Neuronales se obtuvieron las siguientes conclusiones:

- Posibilidad de predicción de la evolución de la demanda por regresión dinámica
- Capacidad de autodaptación a las variaciones de demanda horaria en casos donde la historia deja de jugar un papel relevante.
- Necesidad de entrenamiento frecuente.
- Resistencia a los cambios

2.2.5.4. Aprendizaje no supervisado - Clusterización de perfiles



Un sistema puede aprender sin supervisión directa detectando regularidades o caracterizando estructuras inherentes al conjunto de datos que se está considerando.

Este tipo de sistemas solo pueden aprender de conjuntos de datos que exhiben cierta correlación o redundancia en su estructura interna. La detección de elementos de correlación de información, difícilmente detectables por un observador humano, hacen que estas técnicas sean particularmente atractivas en la estructuración y posterior interpretación de la información contenida implícitamente en bases de datos convencionales.

La técnica central en Aprendizajes no Supervisados es la detección de “clusters” o grupos de datos relacionados. Informalmente, un cluster puede definirse como un grupo de datos cuyos elementos están más cercanos entre si que el promedio y más lejanos de los elementos de otros grupos de lo que sería esperable en término medio.

La identificación de estos cluster produce un esquema general de clasificación de los datos. Los centros de cada cluster proporcionan prototipos representativos de los elementos que lo constituyen. Cada dato de la base queda entonces clasificado en asociación con el prototipo que mejor lo representa.

La formación de clusters constituye un primer nivel de interpretación. Es posible generar niveles más altos asociando clusters próximos. Es decir, generando capas de clusters de clusters y así sucesivamente.

Esta construcción de clases jerarquizadas constituye un proceso de representación conceptual dentro del proceso global de aprendizaje. Cada grupo constituye un “concepto” relevante a la estructura subyacente en la base de datos y el prototipo asociado arroja luz sobre el significado del concepto. Conceptos más altos en la escala jerárquica engloban a los grupos más bajos y son en consecuencia conceptos “más generales” formando una cadena conceptual interpretativa sobre la base de datos de inmensa utilidad.

Este tipo de técnicas fue aplicada en la interpretación de los grupos de datos sobre demanda y en la simulación de situaciones del experto de gestión de predicción con la consiguiente conceptualización al caracterizar patrones o prototipos de situación/solución.

2.2.5.5 Solución adoptada

Estos modelos de regresión dinámica y la utilización de inteligencia artificial a través de redes neuronales con clusterización de perfiles interactuando en una estructura híbrida que premia al modelo más conveniente generan una solución de predicción que ha sido evaluada como adecuada a las necesidades de la distribución de gas, caracterizado por 3 elementos fundamentales:

- Predicción dinámica : Espacio de fases
- Corrección estática: Clustering de perfiles
- Error basado en la divergencia de las trayectorias

El estudio de la dependencia del consumo de gas con las variables de contexto que lo determinan aconsejó en una primera instancia la utilización de una metodología no lineal en las predicciones.

Se decide así la utilización de redes neuronales “Feed Forward” como modeladores, observándose que los resultados obtenidos sobre datos históricos mejoran notablemente la metodología manual anteriormente utilizada.

Se implementa un mecanismo de autoentrenamiento debido a que la historia existente es muy limitada y probablemente contaminada con efectos espúreos.

Se utilizan con buen resultado, modelizaciones diferentes para cambios bruscos de temperatura y para transiciones atenuadas de modo de optimizar la tasa de error sobre todo el periodo histórico.

La experiencia demuestra la importancia de dos factores críticos para la bondad de la previsión, por un lado la previsión de las temperaturas para los próximos días y por otro la estimación correcta del consumo para el final del día en que se efectúa la previsión.

Las mejoras introducidas por el programa son sustanciales en lo que respecta a la reducción de los errores y a la robustez de la metodología a largo término, eliminando el mantenimiento manual de los parámetros de sistema.


Los resultados obtenidos demuestran que conforme aumenta la base de datos histórica las previsiones se hacen más fiables.

2.3. Arquitectura del hardware del sistema

Los requisitos mínimos de hardware son: Pentium a 133 megaHz con 32 Mb de memoria RAM y 2,5 Gb de espacio en el disco rígido, monitor y placa SVGA.

Una característica distintiva del sistema es que trabaja de manera absolutamente integrada con el resto de las aplicaciones que se utilizan en el Control de la Explotación lo que facilita el manejo de datos en tiempo real a través del Sistema SCADA que opera la compañía y de las estaciones meteorológicas propias.

El sistema trabaja sobre una red Token Ring corriendo Windows NT. Cada máquina esta dedicada a una tarea específica de captura de datos, previsión o análisis de resultados.



2.4. Software básico

El software básico es el sistema operativo WINDOWS 95/98/NT.

El desarrollo de los algoritmos de previsión se realizó con C Windows de Microsoft por razones de eficiencia y encapsulados en DLL (Dynamic Link Library) , empleando PDC PROLOG para Windows para los módulos que utilizan herramientas de inteligencia artificial.

La automatización se realiza utilizando el lenguaje Visual Basic para aplicaciones, el lenguaje de macros de EXCEL 5.0.

La aplicación está construida sobre un conjunto de hojas de cálculo EXCEL 5.0, lo que proporciona una gran flexibilidad en la captura de datos, la generación de informes y la graficación de las previsiones.

Se utilizaron las herramientas EVA y ADAN para clusterización de perfiles, productos desarrollados en España.

2.5. Desarrollo de Interfaces

La estructura de Interfaces de la aplicación resulta altamente gráfica, diseñándose un entorno inteligente de análisis comparativo, basado en la potencialidad que otorgan las herramientas de software anteriormente enumeradas, y consiguiendo el objetivo de facilitar la manipulación del entorno de análisis y explotación del modelo.

2.6. Ingreso de Datos


La carga de datos se realiza a través de la transferencia electrónica de archivos desde el sistema SCADA y de la estación meteorológica para los valores horarios de volúmenes emitidos, temperaturas y humedad registradas.

En un archivo específico, y luego de su análisis se ingresan los datos meteorológicos pronosticados, la caracterización del tipo de día y los valores definitivos de volúmenes diarios emitidos, previendo las planillas el ingreso de información por centros de consumo.

Día	Total	Anillo	V.Rosa	Capilla	Temp. max.	Temp. Min.	Mes	Tipo de Día
12/07/96	11,617	9,242	579	1,342	14.8	8.9	7	3
13/07/96	12,308	9,875	611	1,387	10.4	8.8	7	4
14/07/96	12,514	10,208	620	1,339	11.0	7.6	7	5
15/07/96	13,658	11,115	500	1,300	12.0	8.0	7	6
16/07/96	12,927	10,725	470	1,189	14.0	6.0	7	7

2.7. Procedimiento para correr la predicción

Para el cálculo de la previsión de demanda para el próximo día, se requiere la mejor estimación de cual será el valor definitivo del día en curso. A tal efecto deberá de realizarse una predicción para el día en curso con el módulo horario de predicción que tiene en cuenta los volúmenes emitidos hasta el momento de correr el programa.



El sistema efectúa automáticamente la previsión para los tres puntos de entrega y el total, y envía la información a la hoja Resultados del libro DIARIO.XLS.

Día	14/07/96	15/07/96	16/07/96	17/07/96	18/07/96	19/07/96	20/07/96
Tipo Día	5	6	7	1	2	3	4
T.max	11	12	10	12	14	16	16
T.min	7.6	8	6	3	3	9	9

Total	12,514	11,326	10,310	9,680	13,373	11,239	10,597
Anillo	10,206	9,161	8,246	7,916	10,830	9,022	8,384
V.Rosa	620	585	578	505	746	593	582
Capilla	1,339	1,243	1,159	1,019	1,443	1,277	1,277
Otros	350	350	350	350	350	350	350

Anillo	81.6%	80.9%	7.0%	6.4%	81.0%	6.6%	79.1%
V.Rosa	5.0%	5.2%	14.1%	12.9%	5.6%	14.2%	5.5%
Capilla	10.7%	11.0%	4.2%	4.4%	10.8%	3.9%	12.1%
Otros	2.8%	3.1%	3.4%	3.6%	2.6%	3.1%	3.3%

Para cada previsión se visualiza una pantalla con la información histórica donde se pueden efectuar estudios de las previsiones y sus errores.

SANDRA II : Previsión de la demanda GasBAN

Previsión

Opciones

Diaria

Horaria

Total


Anillo

Villa Rosa-Open Door


Capilla-Solis

Todas

Los resultados se presentan de modo gráfico y a través de una tabla de valores. La predicción realizada acompaña índices de evaluación respecto de confianza y tasa de error.



El sistema efectúa la previsión del consumo horario a partir de la hora actual. Es posible visualizar los gráficos como consumo horario o consumo acumulado.



2.8. Utilización del sistema para la exploración de escenarios futuros:

En este caso es necesario generar una base de datos ficticia con datos obtenidos del histórico convenientemente reescalados (DIARIO.XLS y DATOSMET.XLS). La base de datos debe estar completa hasta el periodo donde se quiere iniciar la simulación. El sistema permite escoger la fecha para la cual se quiere hacer la previsión. Si se desea extender la previsión a horizontes mayores que el previsto la base de datos se completará utilizando los valores predichos por el sistema.

2.9. Evaluación y Validación del Modelo



Una vez definidas las condiciones de evaluación se realizaron las validaciones después de evaluar y realizar los ajustes a los modelos. Estos se desarrollaron con el objetivo de conseguir una característica de estabilidad ante cambios y adaptación a distorsiones de los datos de entorno.

3. RESULTADOS:

3.1. Performances del sistema:

Un excelente modo de medir los resultados del sistema consiste en comparar entre sí los valores de predicción de la demanda y la emisión real para un periodo establecido.


A continuación se presentan las tablas comparativas entre la Emisión Total Real y la predicción realizada por “SANDRA” en el periodo Junio-Agosto de los años 1995 y 1996, correspondiente al periodo invernal argentino, el cual constituye una época clave para determinar la calidad de los resultados obtenidos dadas las rápidas variaciones climáticas y las fuertes exigencias de la demanda residencial.



Comparando ambos gráficos se puede observar la mejora que “SANDRA” obtiene en las predicciones del periodo correspondiente al año 1996, debida a su capacidad de auto entrenamiento y a la mejor condición de trabajo del sistema al disponer de un año completo de datos históricos.

Es muy importante tener en cuenta que los resultados incluyen el error producido por la imprecisión de la predicción meteorológica, la cual oscila alrededor del 10% entre la temperatura real y la prevista.

Otro interesante elemento de evaluación es el análisis de la distribución de errores en el periodo Enero – Junio del año 1995 al 1999.



Se puede observar la clara mejoría de la predicción respecto al error asociado, en efecto en el año 1995 solo el 30% de las predicciones tenían un error inferior al 5%, mientras que en el año 1999 el 91% se mantienen por debajo del 5% de error en la predicción.

4.CONCLUSIONES:

Por los resultados obtenidos, se puede afirmar que “SANDRA” satisface las necesidades de predicción de la demanda en base diaria requeridas por GasNatural BAN alcanzando desde los primeros años de trabajo los objetivos básicos establecidos para su etapa de desarrollo.

La notable mejoría del índice de error en la previsión, así como también la confiabilidad en los valores de previsión nos permiten afirmar que la herramienta seleccionada ha sido la correcta, a fin de desarrollar un sistema de previsión para la demanda de gas en un sistema de distribución caracterizado por un alto componente de consumo del tipo residencial, El cual esta muy influenciado por las variaciones en la temperatura.