

Universidad Nacional de Ingeniería  
Facultad de Ingeniería Industrial y Sistemas  
Escuela de Postgrado



Aplicación de Redes Neuronales Artificiales a la Predicción  
y Control de Demanda de Energía Eléctrica en Empresas Industriales

Tesis de Maestría para optar el grado académico de:

Maestro en Ciencias con mención en

Ingeniería de Sistemas

Ing. Juan Manuel Ojeda Sarmiento

Lima - Perú

2009

## ÍNDICE DE CONTENIDO

AGRADECIMIENTO .....	3
DESCRIPTORES TEMÁTICOS .....	10
ABSTRACT .....	11
RESUMEN.....	12
INTRODUCCIÓN.....	14
CAPÍTULO I.....	19
DESCRIPCIÓN DEL PROBLEMA .....	19
1.1 <i>Definición del problema:</i> .....	20
1.2 <i>Sistematización del problema:</i> .....	20
1.3 <i>Objetivo general:</i> .....	21
1.4 <i>Objetivos específicos:</i> .....	22
1.5 <i>Hipótesis científica:</i> .....	22
1.6 <i>Metodología:</i> .....	24
CAPÍTULO II.....	29
MARCO TEÓRICO .....	29
2.1 <i>Revisión crítica bibliográfica</i> .....	32
2.2 <i>Base teórica:</i> .....	40
CAPÍTULO III .....	54
PROGRAMA DE CONTROL DE DEMANDA.....	54
3.1 <i>Arquitectura de red del modelo predictivo:</i> .....	54
3.2 <i>Programación de la red neuronal:</i> .....	72
3.3 <i>Operación de la red neuronal:</i> .....	88
3.4 <i>Prueba del modelo predictivo:</i> .....	94
3.5 <i>Modelo de control de demanda:</i> .....	99
3.6 <i>Caso de aplicación:</i> .....	113

CAPÍTULO IV .....	128
CONCLUSIONES Y RECOMENDACIONES .....	128
4.1 <i>Conclusiones respecto de los objetivos del modelo predictivo:</i> .....	128
4.2 <i>Conclusiones respecto de los objetivos del modelo de control de     demanda:</i> 129	
4.3 <i>Recomendaciones:</i> .....	130
BIBLIOGRAFÍA .....	131
GLOSARIO DE TÉRMINOS .....	134
ANEXOS .....	137

## LISTA DE TABLAS

Tabla 01 - Indicadores de eficiencia .....	17
Tabla 02 - Cronograma de plan de pruebas .....	26
Tabla 03 - Medidores eléctricos principales de la fundición Ilo .....	28
Tabla 04 - Factores considerados en la red neuronal .....	55
Tabla 05 - Tratamiento de la data de entrada.....	56
Tabla 06 - Parámetros a modificar en entrenamiento.....	82
Tabla 07 - Resultados del entrenamiento .....	96
Tabla 08 - Error cuadrático medio .....	98
Tabla 09 - Validación en consumo eléctrico total (total mensual) .....	98
Tabla 10 - Validación en demanda eléctrica total (máximo mensual) .....	98
Tabla 11 - Comparación de valores pronosticados vs. valores reales.....	99
Tabla 12 - Datos de simulación .....	121
Tabla 13 - Cuadro de elección de tema de tesis .....	137
Tabla 14 - Cuadro diagnóstico para el planteamiento del problema.....	138
Tabla 15 - Inventario de equipos .....	139
Tabla 16 - Demanda real vs. demanda simulada .....	140

## LISTA DE FIGURAS

Figura 01 - Bosquejo de un diagrama de carga diaria .....	15
Figura 02 - Demanda media y máxima mensual de fundición Ilo .....	16
Figura 03 - Consumo de energía en la fundición Ilo.....	16
Figura 04 - Descomposición de la hipótesis .....	23
Figura 05 - Comportamiento del error variable .....	33
Figura 06 - Estructura general de una red neuronal.....	41
Figura 07 - Arquitectura de red estática feedforward .....	41
Figura 08 - Red dinámica feedforward .....	42
Figura 09 - Red dinámica con realimentación .....	43
Figura 10 - Arquitectura de RNA dinámicas recurrentes NARX simple.....	45
Figura 11 - Arquitectura paralela y arquitectura serie-paralela.....	46
Figura 12 - Principales funciones de activación RNA .....	47
Figura 13 - Elementos de control de demanda .....	51
Figura 14 - Arquitectura de red del modelo predictivo .....	54
Figura 15 - Demanda cada 15 minutos (18 al 24 -06-07).....	57
Figura 16 - Demanda cada 15 minutos (25-06-07 a 01-07-07) .....	58
Figura 17 - Demanda cada hora (18 al 24-06-2007).....	59
Figura 18 - Demanda cada hora (25-06-07 al 01-07-07).....	59
Figura 19 - Demanda media semanal (23-04-07 al 01-07-07) .....	60
Figura 20 - Demanda máxima semanal (23-04-07 al 01-07-07) .....	61
Figura 21 - Demanda media diaria (23-04-07 al 01-07-07).....	61
Figura 22 - Demanda media diaria (23-04-07 al 01-07-07).....	62
Figura 23 - Producción de ánodos vs. demanda media .....	63
Figura 24 - Producción de ánodos vs. demanda máxima .....	64
Figura 25 - Producción de ácido sulfúrico vs. demanda media y máxima.....	65
Figura 26 - Producción de oxígeno vs. demanda media y máxima .....	66

Figura 27 - Influencia de demanda media diaria de marzo en abril del 2007 .....	67
Figura 28 - Influencia de demanda media diaria de abril en mayo de 2007.....	67
Figura 29 - Influencia de demanda media diaria de mayo en junio del 2007 .....	68
Figura 30 - Influencia del número de capas en las RNA .....	69
Figura 31 - Representación de una TDL en tiempo discreto .....	71
Figura 32 - Arquitectura final de la RNA.....	72
Figura 33 - Procesos de programación de la red neuronal.....	73
Figura 34 - Entrenamiento con 2 capas de neuronas, 2 delays y f.a. 'tansig' .....	83
Figura 35 - Entrenamiento con 1 capa de neuronas, 2 delays y f.a. 'tansig' .....	83
Figura 36 - Entrenamiento con 2 capas de neuronas, 2 delays y f.a. 'tansig' .....	84
Figura 37 - Entrenamiento con 2 capas de neuronas, 4 delays y f.a. 'tansig' .....	84
Figura 38 - Entrenamiento con 2 capas de neuronas, 6 delays y f.a. 'tansig' .....	85
Figura 39 - Entrenamiento con 1 capa de neurona, 6 delays y f.a. 'tansig' .....	85
Figura 40 - Entrenamiento con 1 capa de neurona, 2 delays y f.a. 'logsig' .....	86
Figura 41 - Entrenamiento con 1 capa de neurona, 2 delays y f. a. 'logsig' .....	86
Figura 42 - Entrenamiento con 1 capa de neurona, 2 delays y f.a. 'logsig' .....	87
Figura 43 - Entrenamiento con 2 capas de neuronas, 2 delays y f.a. 'logsig' .....	87
Figura 44 - Ventana inicial de la herramienta GUIDE de Matlab .....	90
Figura 45 - Pantalla de diseño de la interfaz gráfica .....	91
Figura 46 - Pantalla de programación de la interfaz gráfica .....	92
Figura 47 - Pantalla para correr módulo de predicción.....	92
Figura 48 - Pantalla inicial del módulo de predicción.....	93
Figura 49 - Pantalla del modelo luego del entrenamiento .....	94
Figura 50 - Menú desplegable .....	94
Figura 51 - Pantalla del módulo de predicción .....	95
Figura 52 - Entrenamiento de la RNA NARX.....	97
Figura 53 - Diagrama de control .....	104
Figura 54 - Pantalla de simulación .....	105
Figura 55 - Esquema de la planta .....	106
Figura 56 - Modelo de simulación.....	107
Figura 57 - Modelo de simulación.....	109
Figura 58 - Modelo de simulación.....	110
Figura 59 - Modelo de simulación.....	111

Figura 60 - Error (demanda de planta vs. valor deseado 180MW).....	111
Figura 61 - Control del funcionamiento de grupos de equipos .....	112
Figura 62 - Diseño de instalación .....	112
Figura 63 - Diagrama de flujo de la Planta de Ácido 2.....	114
Figura 64 - Modelo de simulación de la Planta de Ácido 2 .....	115
Figura 65 - Diagrama de bloques de los sopladores A y B.....	115
Figura 66 - Pantalla del soplador A (7510C-A) .....	116
Figura 67 - Pantalla del subsistema de control .....	117
Figura 68 - Pantalla del subsistema de proceso .....	118
Figura 69 - Pantalla del modelamiento del soplador .....	119
Figura 70 - Pantalla del cálculo de la producción .....	119
Figura 71 - Demanda real vs. simulada (Planta de Ácido 2).....	122
Figura 72 - Pantalla del subsistema eléctrico .....	123
Figura 73 - Demanda de Planta de Ácido .....	123
Figura 74 - Diagrama eléctrico de planta de limpieza .....	125
Figura 75 - Diagrama eléctrico de área de contacto y ácido débil .....	126
Figura 76 - Curva de la demanda con el control de demanda.....	126
Figura 77 - Programa de control de demanda en Planta de Ácido .....	127
Figura 78 - Estructura de la tesis.....	130
Figura 79 - Esquema distribución energía eléctrica .....	136
Figura 80 - Pantalla de la hoja de cálculo de la simulación .....	142

## DESCRIPTORES TEMÁTICOS

Series temporales,  
Predicción de demanda eléctrica,  
Control de demanda eléctrica,  
Redes neuronales artificiales,  
Uso eficiente de energía eléctrica y  
Gestión de demanda eléctrica.



## **ABSTRACT**

This project presents a model for the management of electricity demand and its application to the Smelter Plant of Southern Peru. It has a module for electric load management, based on the forecast of the hourly electrical load demand of a industrial plant. The module uses a dynamic neural network, with a backpropagation training algorithm to predict the electric load demanded every hour, with an error percentage below of 3%. The load prediction allows to manage the peak demand before its occurrence, distributing the raise of electric load to other hours or improving equipment that increases the demand.

## RESUMEN

La investigación elegida tiene como objetivo aportar a la gestión de la demanda de energía eléctrica de plantas industriales. Se ha construido un programa de control de demanda para reducir la facturación mensual por este concepto, que integra un modelo predictivo basado en redes neuronales artificiales, con la arquitectura (entradas, capas, número de neuronas y salidas) funciones de activación y patrones de entrada, que minimizan el error de pronóstico 3% alrededor del valor real, así como un modelo de control de demanda con los parámetros y métodos matemáticos adecuados.

Se inicia la tesis con una breve introducción acerca de la importancia de la electricidad en la estructura de costos de las empresas. Se presenta, asimismo, la situación actual del sistema de energía eléctrico de la fundición de Southern Peru (caso de aplicación) con descripción de su red industrial, administrativa y sus indicadores de eficiencia de electricidad

En el capítulo N° 1, se presenta la descripción del problema central, su sistematización en sub-problemas y pronóstico, así como la presentación de los objetivos general y específico. Por otro lado, se muestra la hipótesis científica y metodología de la investigación.

En el capítulo N° 2, se presenta un análisis del marco teórico de la investigación, compuesta por la revisión crítica bibliográfica y la base teórica del tema de investigación, para cada uno de los componentes del programa de control de demanda: el modelo predictivo y el modelo de control de demanda.

En el capítulo N° 3, se presenta el programa de control de demanda, que integra el modelo predictivo, basado en una red neuronal, construida con factores calendarios y de producción, que produce una aproximación a la curva de la demanda eléctrica horaria, y pronostica su comportamiento futuro, También se presenta el modelo de control de demanda, cuyo principal objetivo es alisar la curva de la carga horaria; es decir, evitar que se presenten picos de máxima demanda.

Este control de demanda se hace mediante un aparato que actúa automáticamente para desconectar las cargas que no son prioritarias o que no son necesarias en ese momento. Como caso de estudio, se presenta la planta de fundición de Southern Peru, pues las características de su sistema de energía eléctrico se asemejan a las de muchas plantas industriales. En este mismo capítulo, se hace la simulación del funcionamiento del aparato aplicado a la Planta de Ácido 2 de la fundición de Southern Peru.

En el capítulo N° 4, se presentan las conclusiones de la tesis que han sido agrupadas en función de los objetivos de la tesis:

En cuanto al modelo predictivo de demanda, se presenta el tipo de red neuronal, su arquitectura (patrones de entrada, capas, neuronas por capas y funciones de activación), que aproximen el error de pronóstico 3% alrededor del valor real. Este valor de referencia facilita el control de demanda de energía eléctrica.

En cuanto al modelo de control de demanda desarrollado, permitirá mejorar la gestión de la demanda, al evitar que se produzcan demandas no deseadas; asimismo, permitirá reducir el consumo de las plantas. La estrategia de control recomendable está basada en un modelo predictivo, con ventanas deslizantes. Asimismo, el método matemático adecuado para ordenar la secuencia de operación de los grupos de equipos está basado en programación lineal. Finalmente, se presentan las referencias bibliográficas de la tesis y el glosario de términos de la investigación, así como los anexos.

## INTRODUCCIÓN


La energía eléctrica es un recurso estratégico en la producción industrial, su uso se extiende a todas las ramas de la actividad económica, y es un componente importante de la estructura de costos de las empresas de producción y de servicios.

Desde un punto de vista técnico, la energía eléctrica es considerada una forma de energía que se convierte en otras formas como calor, luz, energía mecánica, etc. Sus características son las siguientes:

- a) Con independencia de la fuente primaria utilizada, la energía eléctrica no puede ser almacenada en grandes cantidades.
- b) En la mayor parte de sus usos la electricidad juega el papel de una entrada específica, como el factor productivo que no puede ser reemplazado en el corto plazo.

La demanda facturable es determinada por la máxima demanda del período, que se calcula tomando el mayor valor en un espacio de 15 minutos, medidos cada cinco minutos y presenta oscilaciones horarias, diarias y estacionales (ver figura 01).

Figura 01 - Bosquejo de un diagrama de carga diaria



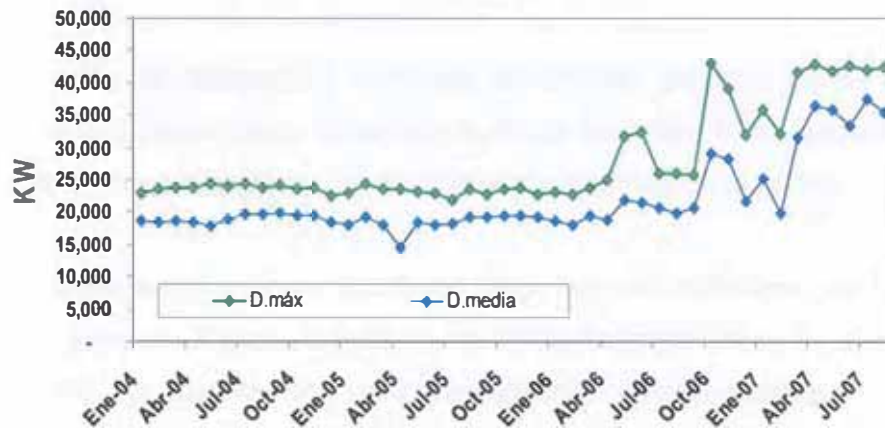
Fuente y elaboración: Brinkmann K., "Integration dezentraler Energieversorgung"

### Situación de la fundición de Southern Peru:

Antes de la modernización de la fundición de Ilo, desde enero de 2004 hasta abril de 2006, su demanda de energía eléctrica media mensual era de 19.5 MW y su demanda máxima de 23.5 MW (ver figura 02).

Durante el proceso de modernización, los valores de demanda máxima y consumo estuvieron oscilantes. Posteriormente, una vez acondicionada la planta, esta demanda media mensual se incrementó hasta 36 MW y la demanda máxima alcanzó 42 MW [2], como se muestra en la figura 02.

Figura 02 - Demanda media y máxima mensual de fundición Ilo

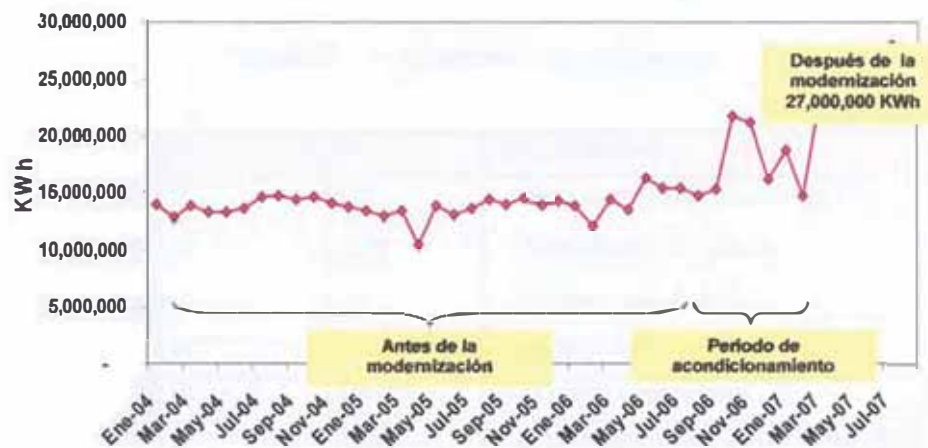


Fuente: Reportes Sistema de Potencia.

Elaboración: Propia

El consumo promedio mensual en la antigua fundición era de 14 MWh. En la nueva planta de fundición, el consumo medio mensual se sitúa en 27 MWh, aproximadamente, tal como se aprecia en la figura 03.

Figura 03 - Consumo de energía en la fundición Ilo



Fuente: Reportes Sistema de Potencia.

Elaboración: Propia

La demanda máxima ha aumentado en 18.5 MW, lo que significa un incremento de 78.7 % respecto de la planta anterior. El consumo de energía ha

aumentado en promedio 13 MWh; es decir, representa un aumento de 92% respecto del consumo de energía de la planta anterior.

Este aumento de demanda y consumo de energía eléctrica ha elevado los montos de facturación de la fundición de Ilo de Southern Peru, situación hace necesaria la mejorar la eficiencia de la energía eléctrica de la planta.

En el caso de la fundición de Southern Peru, hay una deficiente gestión de la demanda, pues se desconoce cuándo se presentarán los picos de demanda y, además, no se cuenta con una herramienta que pronostique con una aproximación aceptable la curva de dicha demanda.

#### Indicadores de eficiencia de red industrial:

Existen 7 indicadores de eficiencia, clasificados en 3 grupos: productividad; es decir, la producción de cada planta respecto de la electricidad consumida. El segundo grupo comprende ratios de energía, como demanda adicional vs. demanda base y energía adicional v.s energía base. Finalmente, se menciona el indicador de error de predicción, cuyo detalle se presenta en la tabla 01.

Tabla 01 - Indicadores de eficiencia

	INDICADOR	RATIO	DESCRIPCIÓN
PRODUCTIVIDAD	I1	C/E	Productividad de Concentrado
	I2	An/E	Productividad de Ánodos
	I3	Ac/E	Productividad de Ácido
	I4	Ox/E	Productividad de Oxígeno
ENERGÍA	I5	DA/DB	Razón de Capacidades
PREDICCIÓN	I7	ERMS	Error cuadrático medio (M. Predicción)

Fuente y elaboración propia

Donde:

- E : Energía consumida en un mes (kWh)
- C : Concentrado fundido en un mes (TM)
- An : Ánodos producidos en un mes (TM)
- Ac : Ácido sulfúrico producido en un mes (TM)
- Ox : Oxígeno gaseoso producido en un mes (TM)
- EB : Energía base consumida en un mes (KWh)
- EA : Energía adicional consumida en un mes (KWh)
- DB : Capacidad base demandada en un mes (KW)
- DA : Capacidad adicional demandada en un mes (KW)



## CAPÍTULO I

### DESCRIPCIÓN DEL PROBLEMA

Las empresas, en su mayor parte, presentan sobrecostos de energía eléctrica que se originan con los picos que sobrepasan la demanda máxima contratada y se reflejan en sus altos montos de facturación mensual. Estos son *síntomas* de la deficiente gestión de demanda de energía eléctrica (*problema*), debido al desconocimiento de patrones de consumo, a la ausencia de planificación y a la falta de herramientas de gestión de demanda (*causas*).

En la facturación de energía eléctrica, se consideran generalmente 3 cargos, que son los siguientes:

- a) Consumo (KWh),
- b) Demanda (KW), y
- c) Factor de potencia (%).

La demanda representa la cantidad total de energía activa que se requiere al mismo tiempo de la red. Ésta presenta oscilaciones horarias, diarias y estacionales, estando también influida por la actividad productiva de la planta.

Como caso de estudio, se ha considerado la planta de fundición de Southern Peru, pues las variables consideradas en este caso, se asemejan a las de muchas plantas industriales del país; asimismo, se cuenta con información histórica de la carga y datos de producción que permitirán desarrollar el modelo predictivo.

## **1.1 Definición del problema:**

Para la formulación de problema, se ha revisado bibliografía especializada en programas de control de demanda y redes neuronales, que permita establecer el tipo de investigación (exploratoria o analítica) y sus límites en términos de espacio, tiempo y universo. Este planteamiento se reduce a la siguiente pregunta:

¿**Cómo** mejorar la actual gestión de demanda de energía eléctrica en las empresas industriales y reducir la facturación mensual por este concepto, mediante un **programa de control de demanda**, que integre un **modelo predictivo** basado en redes neuronales artificiales, con la arquitectura (entradas, capas, número de neuronas y salidas) funciones de activación y patrones de entrada, cuyo error de pronóstico es de 3% alrededor del valor real<sup>1</sup>, así como un **modelo de control de demanda** con los parámetros y métodos matemáticos adecuados?

## **1.2 Sistematización del problema:**

La sistematización del problema para elaborar el programa de control de demanda, se hizo sobre las bases de las siguientes preguntas:

### **1.2.1 Modelo predictivo:**

- ¿Qué **tipo de red neuronal** tiene un error de pronóstico de 3% alrededor del valor real, para su aplicación en el programa de control de demanda?
- ¿Cuál es la **arquitectura de red neuronal (entradas, capas, número de neuronas y salidas) y funciones de activación** adecuados?
- ¿Qué **patrones de entrada** se deben considerar en la red neuronal del modelo predictivo?

---

<sup>1</sup> El 5 % es el mínimo porcentaje de error que arrojan los métodos alternativos de pronóstico, de acuerdo a la investigación de Christian Hufendiek en su aplicación de redes neuronales [1997].

### 1.2.2 Modelo de control de demanda:

- ¿Qué **parámetros** se deben considerar en el **modelo de control de demanda** de energía eléctrica?
- ¿Qué **método matemático optimiza la secuencia de operación de los equipos** de las plantas de la fundición de Ilo?

El pronóstico de esta situación en la fundición de Ilo de Southern Peru indica que se seguirán generando **sobrecostos de energía eléctrica** en las empresas **por la deficiente gestión de la demanda**. **Asimismo se desaprovecharán ingentes recursos económicos por dichas ineficiencias**, con su consiguiente perjuicio económico.

Es necesario mejorar la gestión demanda de energía eléctrica de la fundición de Southern Peru, que produzca ahorros a la empresa, sobre la base de un modelo predictivo de demanda horaria, basado en redes neuronales, para facilitar la implementación de un programa de gestión de demanda de energía eléctrica.

### 1.3 *Objetivo general:*

El objetivo general del presente trabajo es mejorar la actual gestión de demanda de energía eléctrica de las empresas industriales, buscando reducir la facturación mensual por este concepto, mediante un **programa de control de demanda** que integre un **modelo predictivo** basado en redes neuronales artificiales, con la arquitectura (entradas, capas, número de neuronas y salidas) funciones de activación y patrones de entrada, cuyo error de pronóstico es de 3% alrededor del valor real<sup>2</sup>, así como un **modelo de control de demanda** con los parámetros y métodos matemáticos adecuados

---

<sup>2</sup> El 5 % es el mínimo porcentaje de error que arrojan los métodos alternativos de pronóstico, de acuerdo a la investigación de Christian Hufendiek en su aplicación de redes neuronales [1997].

#### **1.4 Objetivos específicos:**

Los objetivos específicos son los siguientes:

##### **1.4.1 Modelo predictivo:**

- Determinar el **tipo de red neuronal** para el modelo predictivo de demanda de energía eléctrica, cuyo margen de error es de 3 % alrededor del valor real, para su aplicación en el programa de control de demanda. Establecer la **arquitectura de red neuronal** (entradas, capas, número de neuronas y salidas) y **funciones de activación** adecuados.
- Determinar los **patrones de entrada** adecuados para la red neuronal del modelo predictivo.

##### **1.4.2 Modelo de control de demanda:**

- Elegir los **parámetros del modelo de control de demanda** de energía eléctrica.
- Determinar el **método matemático adecuado para optimizar la secuencia de operación de los equipos** de las plantas de la fundición de Ilo.

#### **1.5 Hipótesis científica:**

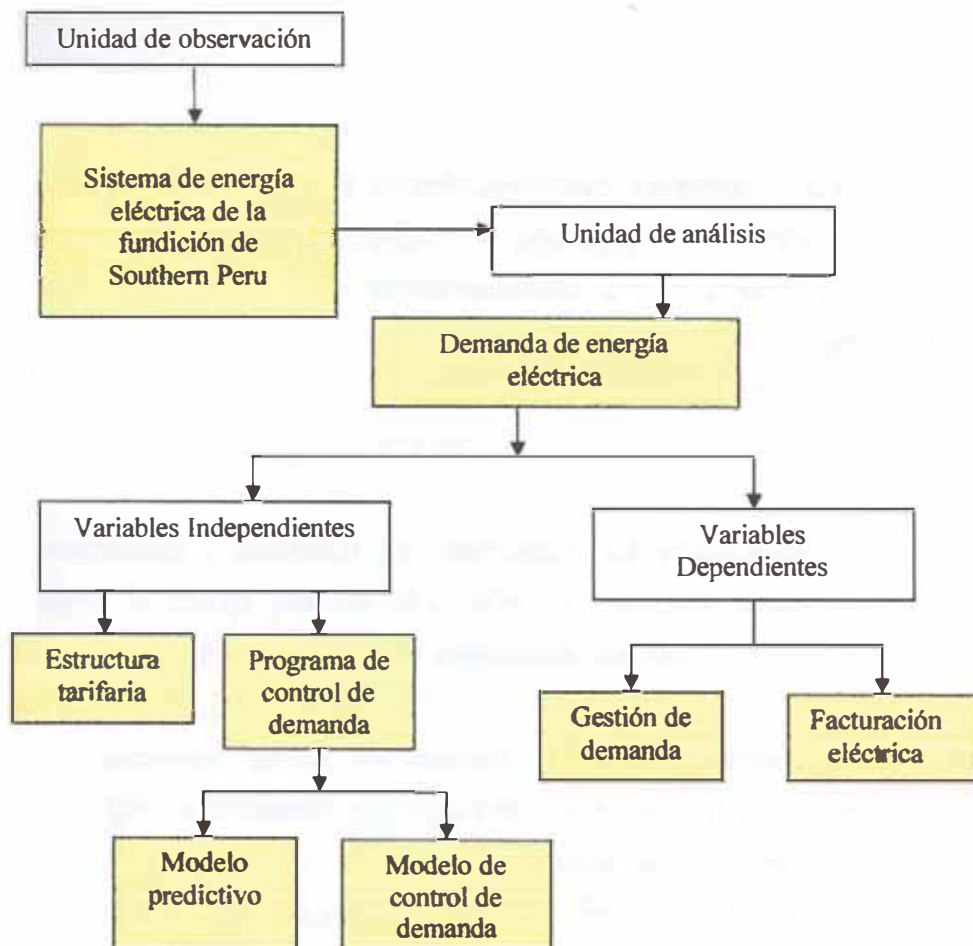
Si se desarrolla un programa de control de demanda, que integre un modelo predictivo basado en redes neuronales artificiales, con la arquitectura (entradas, capas, número de neuronas y salidas) funciones de activación y patrones de entrada, cuyo error de pronóstico es de 3% alrededor del valor real <sup>3</sup>, así como un modelo de control de demanda con los parámetros y métodos matemáticos adecuados, se mejorará la actual gestión de demanda de la fundición de Ilo y se reducirá la facturación mensual por este concepto.

---

<sup>3</sup> El 5 % es el mínimo porcentaje de error que arrojan los métodos alternativos de pronóstico, de acuerdo a la investigación de Christian Hufendiek en su aplicación de redes neuronales [1997].

Esta hipótesis se puede plasmar en la figura 04:

Figura 04 - Descomposición de la hipótesis



Fuente y elaboración propias

Las variables de la hipótesis son el modelo predictivos de demanda de energía eléctrica, el control de demanda, así como la gestión de demanda y la facturación de energía eléctrica.

#### 1.5.1 Variables independientes:

- Modelo predictivo
- Control de demanda

### **1.5.2 Variables dependientes:**

- Gestión de demanda y facturación
- Facturación eléctrica

### **1.6 Metodología:**

Se ha utilizado inicialmente el método deductivo, tomando en cuenta trabajos anteriores sobre sistemas inteligentes orientados al pronóstico de series temporales, para facilitar la implementación del programa de control de demanda. Luego se ha hecho uso del método inductivo al generalizar los resultados del programa aplicado a Southern Peru al sector industrial del país. La tesis se desarrolló en cuatro etapas:

- a) Recopilación y selección de información. La información de campo se levantó a través del servidor IION<sup>4</sup> y mediante cuestionarios a los involucrados. Para procesar la información se usó SPSS, y algunos datos en Excel.
- b) El tratamiento de la información, incluyó el análisis: descripción, indización, clasificación, catalogación, condensación y almacenamiento, y finalmente su difusión, basada en consulta de documentos, reprografía, publicaciones, difusión selectiva de información, asesoramiento y formación de bibliografías.
- d) Construcción del modelo predictivo, basado en redes neuronales.
- d) Validación del modelo predictivo.- En esta etapa se evaluó la precisión del modelo, comparando los resultados del modelo predictivo con los valores reales del período de estudio.
- c) Desarrollo del programa de control de demanda con el método matemático y los parámetros adecuados.

---

<sup>4</sup> Servidor IION

En el caso de la presente investigación, se censó al 100% de los equipos de las plantas que forman parte del sistema de energía eléctrica de la fundición de Ilo. Seguidamente, se han realizado pruebas de campo, considerando la disponibilidad de las fuentes, la facilidad de su acceso y las bases de datos. En el caso del servidor IION, se han almacenado los datos de demanda validados por el área de Sistemas de Potencia.

En el caso del servidor Wonderware, se tuvo un manejo de datos mucho más versátil, pues se trabajó con bases de datos SQL, por lo que la toma de datos pudo realizarse en distintos períodos; sin embargo, esta data fue tomada con medidores propios de Southern Peru, validados con los reportes mensuales del Sistemas de Potencia, que trabajan con un medidor diferente, que fue compartido por la empresa de generación eléctrica ENERSUR, con el siguiente procedimiento:

- Cargar la data del servidor IION, diariamente a la base de datos del modelo de predicción.
- Cargar la data del servidor Wonderware (Active Factory) cada 5 días a la base de datos del módulo de predicción.
- Cargar el reporte de consumo de energía del área de Sistemas de Potencia, mensualmente y validarla con la data recogida en la base de datos.
- Realizar la predicción de demanda de los próximos 3 meses, cada 15 días.
- Realizar la validación de la predicción, todos los lunes.

La data ha sido obtenida y clasificada a partir de información histórica, mientras que la data real ha sido obtenida y clasificada a partir de datos actuales. Para la verificación del correcto funcionamiento del módulo de predicción, se revisó la demanda real incluida en la facturación mensual de la fundición.

Tabla 02 - Cronograma de plan de pruebas

Fecha	Servidor IION	Wonderware (A.Factory)	Reportes Potencia	Predicción	Validación
01-Ago	X		X	X	
02-Ago	X				
03-Ago	X				
04-Ago	X				
05-Ago	X	X			
06-Ago	X				X
07-Ago	X				
08-Ago	X				
09-Ago	X				
10-Ago	X	X			
11-Ago	X				
12-Ago	X				
13-Ago	X				X
14-Ago	X				
15-Ago	X	X		X	
16-Ago	X				
17-Ago	X				
18-Ago	X				
19-Ago	X				
20-Ago	X	X			X
21-Ago	X				
22-Ago	X				
23-Ago	X				
24-Ago	X				
25-Ago	X	X			
26-Ago	X				
27-Ago	X				X
28-Ago	X				
29-Ago	X				
30-Ago	X				
31-Ago	X	X		X	
01-Sep	X		X		
02-Sep	X				
03-Sep	X				X
04-Sep	X				
05-Sep	X	X			
06-Sep	X				
07-Sep	X				
08-Sep	X				
09-Sep	X				
10-Sep	X	X			X
11-Sep	X				
12-Sep	X				
13-Sep	X				
14-Sep	X				
15-Sep	X	X		X	
16-Sep	X				
17-Sep	X				X
18-Sep	X				
19-Sep	X				
20-Sep	X	X			
21-Sep	X				
22-Sep	X				
23-Sep	X				
24-Sep	X				X
25-Sep	X	X		x	

Fuente y elaboración propias



Se utilizaron instrumentos de medición para la visualización de ciertas magnitudes eléctricas que son:

- Voltaje [V]
- Corriente [A]
- Factor de potencia [fdp]
- Potencia consumida [KW]
- Energía consumida [KWh]

Estos medidores están ubicados estratégicamente para que cada carga (equipos conectados a la energía eléctrica) presente las magnitudes antes enunciadas.

Esta unidad permitió tener muestras de los valores registrados y en algunos casos, la visualización remota de las medidas registradas, a través de la comunicación vía la red industrial Modbus.

Asimismo, se realizó la identificación física creándose una codificación única de cada medidor ubicado en las áreas de la planta de oxígeno 2 y planta de ácido 2, que facilita el reconocimiento seguro de cada medidor.

El área eléctrica donde se recibe la alimentación externa de la empresa ENERSUR es conocida como el Área 611, donde se encuentran las barras redundantes de alimentación principal de toda la fundición con los medidores totalizadores de todas las áreas.

En la siguiente tabla 03, se observan los medidores totalizadores de la fundición y sus respectivas cargas.

Tabla 03 - Medidores eléctricos principales de la fundición Ilo

Medidor	Descripción
1 016 (HCB-653)	138/13.8kV Transformer switch yard
1 017 (HCB-654)	138/13.8kV Transformer switch yard
1 500 (VCB661)	611-MVS-001 (Bar 1)
1 502	Acid plant 2 (Area 410)
1 503	Sea water intake/ Desalination plant transformer yard (AREA 620/640)
1 504	Isasmelt transformer yard (AREA 230)
1 505	Smelter 3
1 506	Smelter 2
1 507	Smelter 1
1 501 (VCB662)	611-MVS-001 (Barra 2)
1 508	Smelter 1
1 509	Smelter 2
1 510	Smelter 3
1 511	Isasmelt transformer yard (AREA 230)
1 512	Sea water intake/ Desalination plant transformer yard (AREA 620/640)
1 513	Oxygen plant 2 (AREA 440)

Fuente: Planos eléctricos

Elaboración: Propia

El tratamiento de la información incluyó el análisis: descripción, indización, clasificación, catalogación, condensación y almacenamiento, y finalmente la difusión, basada en consultas de documentos, reprografía, publicaciones, difusión selectiva de información, asesoramiento y formación de bibliografías.

## CAPÍTULO II

### MARCO TEÓRICO

Para implementar el programa de control de demanda, se desarrolló un modelo matemático de predicción horaria, evaluándose, preliminarmente, los modelos de regresión lineal, el uso de ARIMA y las redes neuronales.

a) El modelo de regresión lineal por el método de mínimos cuadrados permite encontrar la ecuación de la recta "que mejor se ajusta a un conjunto de puntos", así como el grado de correlación lineal entre un conjunto de pares de valores numéricos.

Este método matemático se aplica frecuentemente para efectuar pronósticos por su relativa sencillez. Se asume que la variable pronosticada  $Y$  depende de las variables (factores)  $X_1, X_2, \dots, X_p$  según una función  $f$  que para cada juego de datos  $(Y_i, X_{1i}, X_{2i}, \dots, X_{pi})$  se tiene que  $Y_i = f(X_{1i}, X_{2i}, \dots, X_{pi}) + \varepsilon_i$ , donde  $\varepsilon_i$  es su correspondiente error.

Asumiendo un modelo lineal, la relación entre los datos tiene la forma:

$$Y_i = \beta_0 + \beta_1 \cdot X_{1i} + \beta_2 \cdot X_{2i} + \dots + \beta_p \cdot X_{pi} + \varepsilon_i \quad (2)$$

Las variables  $X_i$  pueden representar directamente los factores de influencia o ser formados mediante la transformación de las variables de influencia. Estas funciones de transformación en el caso de modelos lineales pueden también ser funciones no lineales, que tiene en cuenta los saltos y los umbrales.

b) ARIMA es un modelo estadístico que utiliza variaciones y regresiones de datos estadísticos con el fin de encontrar patrones para una predicción hacia el

futuro. Para explicarlo matemáticamente, se toma el modelo de regresión inicial:

$$Y_i = \beta_0 + \beta_1 \cdot X_{1i} + \beta_2 \cdot X_{2i} + \dots + \beta_p \cdot X_{pi} + \varepsilon_i \quad (3)$$

Donde Y es la variable a pronosticar,  $X_1$  y  $X_2$  son los factores de influencia (variables explicativas)  $\beta_0$  hasta  $\beta_p$  son los coeficientes de regresión lineal, y  $\varepsilon$  el error residual. Si se representan las variables explicativas  $X_1=Y_{t-1}$ ,  $X_2=Y_{t-2}$  y  $X_p=Y_{t-p}$ , entonces se tiene que:

$$Y = \beta_0 + \beta_1 \cdot Y_{t-1} + \beta_2 \cdot Y_{t-2} + \dots + \beta_p \cdot Y_{t-p} + \varepsilon_t \quad (4)$$

Es un modelo dinámico de series de tiempo; es decir, las estimaciones futuras vienen explicadas por los datos del pasado y no por variables independientes.

$$Y = \beta_0 + \beta_1 \cdot \varepsilon_{t-1} + \beta_2 \cdot \varepsilon_{t-2} + \dots + \beta_p \cdot \varepsilon_{t-p} + \varepsilon_t$$

- Estimación del modelo,
- Diagnóstico del modelo
- Verificación del pronóstico y razonamiento.

**c)** Modelos de redes neuronales que aproximan funciones no lineales con un error aceptable, y cuya teoría se desarrolla en el apartado 2.3.

En el trabajo de Christian Meisenbach, "*Lastprognose konventionell oder mit neuronalen Netzen - ein Vergleich*"; es decir, "*Comparación de pronósticos de carga- métodos convencionales o con redes neuronales*", se estableció la superioridad de esta última sobre los métodos convencionales de regresión lineal para el pronóstico de la carga horaria, que resulta aplicable al de la demanda de energía eléctrica.

Esta evaluación se hizo, tomando como casos de estudios, tres sistemas de energía en diferentes ubicaciones geográficas y tamaños, con distintos

comportamientos de consumo. Se eligieron los suministros de electricidad de un pueblo de Alaska y de la región Sur de Alemania, y el de provisión de electricidad y calefacción de una ciudad del Estado de Sachsen en Alemania.

Los dos primeros casos de evaluación (el pueblo de Alaska y la región Sur de Alemania) son útiles para comparar la potencia de pronóstico de estos modelos matemáticos. Los criterios de evaluación se centraron en los errores de predicción o pronóstico; es decir la diferencia entre los valores pronosticados  $P_{prog}$  y los valores reales  $P_{real}$ , considerándose el error cuadrático medio como indicador de evaluación:

$$\text{Root Mean Square Error} = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_{prog} - P_{real})^2}$$

Se aprecia, que el error cuadrático medio (RMSE) es de 3.21 y 58.85 para el pueblo de Alaska y la región Sur de Alemania respectivamente, utilizando las redes neuronales, y estos valores son de 3.30 y 59.06 mediante la regresión lineal.

Otro trabajo a considerar para esta elección es “*A Neuro-Fuzzy Approach for Modelling Electricity Demand in Victoria*” de Ajith Abraham y Baikunth Nath, que establece una comparación de pronóstico de demanda en Victoria, Australia, mediante las redes neuronales y el ARIMA (Autoregressive Integrated Moving Average). Los resultados establecieron un error cuadrático medio (Root Mean Square Error) de 0.0323 para redes neuronales y 0.0423 para el método ARIMA. De todas las alternativas de solución, la que presenta una mejor aproximación a la función de demanda horaria es el método predictivo con redes neuronales.

## 2.1 Revisión crítica bibliográfica

**2.1.1 Modelo Predictivo.-** Las predicción de series temporales tiene diversos campos de aplicación, como las finanzas (retornos, stocks de mercados), hidrología (desbordes de ríos) e ingeniería (consumo de electricidad). Existen métodos de aproximación a las funciones no lineales de estas aplicaciones, que se orientan al pronóstico de corto y largo plazo.

Para esta investigación, se ha revisado la bibliografía de predicciones de series temporales de largo plazo. Como antecedentes de la aplicación de redes neuronales, se pueden citar los siguientes trabajos:

a) La investigación titulada “*Time series forecasting: Obtaining long term trends with self-organizing maps*”, es decir, predicción de series temporales para obtener tendencias a largo plazo, basado en mapas Kohonen de auto-organización, desarrollado por un equipo de investigadores de la Universidad Católica de Lovaina, Helsinki University of Technology, Université Paris I y Université Paul Sabatier Toulouse 3[4].

En este trabajo, se utilizaron los mapas Kohonen de auto-organización para la previsión de series temporales, mediante un método de pronóstico especialmente diseñado para la predicción de tendencias multidimensionales de largo plazo; es decir, un vector con diversos valores; sin embargo, permiten también predecir valores escalares.

El método de aproximación desarrollado en esta investigación, se basó en el algoritmo de SOM (Self Organizing Map), dividiéndose en dos etapas: la caracterización y el pronóstico. En la etapa de caracterización se pudo evaluar el aprendizaje, mientras que la previsión pudo ser vista como un procedimiento de generalización.


Se tomó como uno de los casos de aplicación de esta serie temporal, el caso polaco de consumo eléctrico de 1989 a 1996, que requería la predicción de un

vector de 24 valores horarios. Al final, el modelo replicó la tendencia del modelo real, con la media y un intervalo de confianza de 95%; sin embargo, el modelo se apoya en técnicas adicionales como el método de Montecarlo que dificulta su aplicación comercial.

**b)** El trabajo de Edgar Sánchez, Alma Alanis y Jesús Rico, denominado “*Predicción de la demanda eléctrica, usando redes neuronales entrenadas por Filtro de Kalman*”, En dicha investigación, se desarrolló un modelo predictivo basado en redes neuronales artificiales, tipo perceptrón multicapa recurrente, con el uso del Filtro de Kalman Extendido (EKF) para el entrenamiento de una red MLP (Multilayer Perceptron).

En su arquitectura, se utilizó una sola capa oculta con 15 neuronas (función de activación logsig) y sólo una en la capa de salida de la red (función lineal), cuya medición es usada por el Filtro de Kalman. El entrenamiento duro 35 iteraciones, con el cual se alcanzaron criterios de error variable, con valores mínimos cercanos a 0 hasta  $35 \times 10^{-4}$ , según se aprecia de la figura 05.

Figura 05 - Comportamiento del error variable



Fuente y elaboración: Edgar Sánchez, Alma Alanis y Jesús Rico

La lección aprendida de este trabajo es que las redes dinámicas resultan mucho más potentes para establecer una predicción de una función no lineal como la demanda eléctrica, al comparar el error cuadrático medio de la predicción de dicho tipo de red con el modelo de redes estáticas.

c) Igualmente importante resultan los trabajos de modelos predictivos para prevenir la intensidad de los huracanes, elaborado por Venero Castro [6].



d) Continúa la evaluación de aplicaciones de redes neuronales en modelos predictivos, con la investigación titulada "*Indicadores líderes, redes neuronales y predicción de corto plazo*", desarrollada por Javier Kapsoli Salinas y Brigitt Bencich Aguilar [7], consistente en un modelo de predicción de corto plazo del nivel de actividad económica del país.

Para su construcción, se utilizó el filtro de Baxter & King que permitió descomponer la serie de PBI mensual en sus tres componentes: estacional, cíclico y tendencial. Posteriormente el componente cíclico futuro fue estimado y pronosticado a partir de un conjunto de variables líderes que adelantan al Producto Bruto Interno, asumiéndose un modelo lineal de redes neuronales entre dichas variables y el ciclo del PBI.

Los demás componentes fueron estimados utilizando modelos econométricos estándares. Finalmente, se agregaron sus tres componentes para obtener un indicador de la evolución futura del PBI. La predicción que se obtuvo muestra un nivel razonable de confiabilidad, por lo que el índice propuesto puede ser una herramienta para la toma de decisiones dada su pronta disponibilidad respecto a las estadísticas oficiales.

Esta investigación demuestra la potencia de las redes neuronales para predecir escenarios complejos, como el cálculo del PBI de un país en el que concurren múltiples variables macroeconómicas.

e) También es importante citar el trabajo de Pérez Ortiz [9] para el desarrollo de modelos predictivos, basados en redes neuronales recurrentes de tiempo discreto. Este trabajo estudia la aplicación de distintos modelos de redes neuronales recurrentes de tiempo discreto a diversas tareas de carácter predictivo.

Las redes neuronales recurrentes son redes neuronales que presentan uno o más ciclos en el grafo definido por las interconexiones de sus unidades de procesamiento. La existencia de estos ciclos les permite trabajar de forma

innata con secuencias temporales. Las redes recurrentes son sistemas dinámicos no lineales capaces de descubrir regularidades temporales en las secuencias procesadas y pueden aplicarse, por lo tanto, a multitud de tareas de procesamiento de este tipo de secuencias. Esta tesis se centra en la aplicación de las redes neuronales recurrentes a la predicción del siguiente elemento de secuencias de naturaleza simbólica o numérica.

No obstante, la predicción en sí no es el objetivo último de dicha tesis, sino la capacidad predictiva de las redes recurrentes para la comprensión de señales de voz o de secuencias de texto, sobre la base de inferencia de lenguajes regulares o sensibles al contexto, y a la claridad de las palabras homógrafas de una oración.

Los modelos concretos de redes utilizados en dicha investigación fueron, principalmente, la red recurrente simple, la red parcialmente recurrente y el modelo neuronal de memoria a corto y largo plazo; este último permitió superar el llamado problema del gradiente evanescente que aparece cuando los intervalos de tiempo mínimos entre eventos interdependientes son relativamente largos. Para determinar valores correctos de los parámetros libres de las redes se usaron dos algoritmos, el clásico algoritmo del descenso por el gradiente y una forma del filtro de Kalman extendido.

f) Asimismo, se ha revisado la investigación de Carlos Mallo sobre el uso de redes neuronales en la predicción de la demanda eléctrica horaria [10]. En este trabajo, se exploró su aplicabilidad en el terreno de la economía cuantitativa como instrumento de modelización y predicción no paramétrica. Para tal fin, se desarrolló un modelo de red neuronal artificial que pronostica la demanda horaria de energía eléctrica con datos reales. Los resultados así obtenidos fueron comparados con los ofrecidos por las metodologías convencionales de ajuste y predicción. El modelo neuronal propuesto fue capaz de predecir la evolución horaria de la demanda eléctrica con una precisión del 98%.

Esta investigación permitió demostrar la incidencia que tienen variables como la temperatura o el calendario en la evolución de la curva de carga eléctrica. Sin embargo no se pudo establecer el tipo de relación que vincula dichas variables con la demanda eléctrica. En este sentido la red hizo las veces de una especie de caja negra que procesa la información de entrada para generar una salida que se ajusta a un determinado criterio o norma.

g) La investigación de [Meisenbach Christ y Gnüchtel](#), Lastprognose konventionell oder mit neuronalen Netzen - ein Vergleich [11] en la que se efectúa una comparación de herramientas de predicción entre los modelos convencionales de pronóstico, como la regresión lineal y las redes neuronales. Para llevar a cabo este análisis se consideró la predicción de demanda eléctrica de corto plazo en tres ámbitos geográficos distintos, cuya evaluación más detallada se puede apreciar en el apartado a. del segundo capítulo.

h) El trabajo de Raquel Gareta, Luis M. Romeo, Antonia Gil, Alberto Monzón, denominado "*Las redes neuronales como herramienta para predecir el precio de la energía eléctrica*" [12]. Esta investigación tuvo como objetivo predecir la evolución de los precios, considerando trabajos previos de modelización y predicción de demanda de la electricidad a corto, medio y largo plazo.

Este trabajo permitió demostrar que las redes neuronales pueden ser utilizadas tanto para la predicción como la simulación de comportamientos complejos, utilizando una estructura de red neuronal en la que se introduce el conocimiento disponible acerca del funcionamiento del mercado y de los precios.

i) Asimismo, se revisó el pronóstico de series temporales de Petridis and A. Kehagias [13] desarrollado para la previsión de carga de la Corporación Pública de Energía Griega. Dicha aplicación se denominó PREMONN, basada en redes neuronales para la previsión de carga a corto plazo, considerando algoritmos probabilísticos, que pueden ser utilizados para la predicción de series temporales, clasificación e identificación.

Asimismo, el conjunto de elementos que han servido de sustento para plantear la viabilidad de la tesis, está conformado por una diversidad de aplicaciones tales como por ejemplo:

- Los estudios de [Hufendiek Kai \[14\]](#) y [CIGRE Working group \[15\]](#).
- Análisis de modelos de previsión de demanda de corta duración [16-19].
- Detección de fraudes: Encontrar los patrones y tendencias de compra para detectar comportamientos fraudulentos en el momento de compras con tarjeta de crédito.
- Riesgo crediticio: Se utiliza información histórica de clientes para evaluar la factibilidad de otorgar un préstamo, clasificándolos en intervalos según, su comportamiento a través del tiempo.

**2.1.2 Control de demanda.**- Desde el punto de vista de las matemáticas, los problemas de optimización de control se encuentran entre los más difíciles de resolver. Las mayores bases teóricas en la teoría de control óptimo fueron desarrolladas por Bellman en su modelo de programación dinámica, y por Pontryagin, en su postulado del mínimo principio. El modelo de programación dinámica es un enfoque natural para el desarrollo de relaciones básicas en control óptimo de tiempo discreto.

En esta investigación, se han estudiado algunas de los más importantes métodos de optimización de control aplicados recientemente en la industria, basados en programación lineal y optimización no lineal (LP y PNL), programación dinámica (DP) y lineal-cuadrática control óptimo (HQ).

a) En programación lineal, hay una metodología expuesta en [22 - Braun1989a] para el control de sistemas de agua fría que no tienen un buen almacenamiento térmico, para lo cual, se desarrolló un algoritmo basado en optimización no lineal para el control de variables continuas. En este proceso, se utilizó una aproximación de forma lineal y cuadrática para el costo de operación y la salida de cada uno de los componentes del sistema de agua fría.

El sistema de enfoque implica relacionar el sistema general de consumo de energía con una sola función, para la rápida determinación de las variables de control óptimo considerando sólo la medición de potencia total a través de una serie de condiciones. La estimación de los coeficientes de este modelo de sistema empírico involucra la regresión en los resultados del algoritmo de optimización basado en componentes como una herramienta de simulación.

En otro trabajo estrechamente relacionado [Braun 1989b], se revisó su metodología de optimización utilizada como una herramienta para la investigación de los sistemas de agua refrigerada en control óptimo. Con esta herramienta, se desarrollaron las directrices para un rendimiento casi óptimo. Braun [1990] estudió la dinámica de control de edificios, el ajuste dinámico de la temperatura interior para reducir al mínimo los gastos de funcionamiento general mediante la aplicación de técnicas de optimización dinámica de simulaciones por ordenador de los edificios y equipo.

**b)** En programación dinámica, es conocida la metodología de Henze [1997] para la determinación de estrategias de control óptimo en sistemas de almacenamiento térmico de energía y un control óptimo predictivo para dichos sistemas. También, se analizó el trabajo de Rossi y Braun [1996] sobre programación dinámica para obtener un servicio óptimo de horarios y costos de la limpieza de los condensadores y evaporadores de aire acondicionado.

Asimismo, se revisó el modelo multi-criterio de [D'Cruz y Radford 1987] para ayudar a los diseñadores de edificios en la elección de forma y construcción de tuberías paralelas en la fase de diseño esquemático de los edificios. El modelo considera cuatro criterios de desempeño: carga térmica, disponibilidad de luz natural, planificación de la eficiencia y coste de capital. El óptimo de Pareto fue la optimización dinámica de programación empleada.

**c)** Un problema con sistemas lineales y cuadráticos costo se define como un problema lineal-cuadrático (LQ). Los controles óptimos se puede obtener

analíticamente, por medio de la ecuación de Riccati [Bertsekas 2000]. Las aproximaciones lineales y cuadráticas son válidas, en muchos casos, para investigaciones de carga en edificios. Sin embargo, LQ no se ha utilizado mucho, posiblemente debido a la complejidad en los sistemas reales.

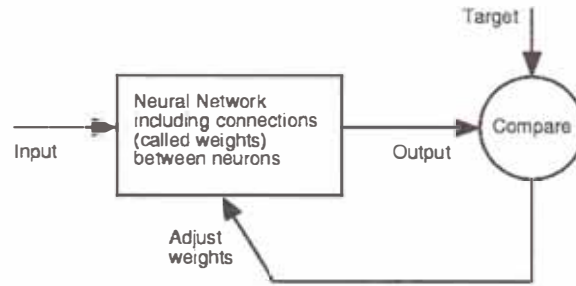
En cuanto a aplicaciones comerciales, se han analizado diversas propuestas comerciales para el control de demanda. Entre ellas, el modelo de control de demanda de Schneider Electric para eliminar picos de demanda con un control automático sincronizado en tiempo real, mediante el uso de algoritmos de demanda predictiva [20]. Asimismo, se han revisado otras propuestas como las de **ENth Energy** y **Sustanaible Energy Management** y **DL Steiners Electrical Engineers** [21]; pero ninguna ofrece información teórica acerca de sus modelos de control.

## **2.2 Base teórica:**

**2.2.1 Las redes neuronales artificiales.-** Son sistemas compuestos de elementos de procesamiento simples y altamente interconectados, llamados neuronas, que operan en paralelo. Estos elementos están inspirados en el sistema nervioso biológico (ver figura 06).

Como en la naturaleza, la función de la red está determinada casi en su totalidad por las conexiones de sus elementos. Uno puede entrenar una red neuronal para que se desarrolle una función determinada ajustando los valores de las conexiones (pesos) entre sus elementos.

Figura 06 - Estructura general de una red neuronal




Fuente: Matlab Help

Son modelos no lineales de gran flexibilidad que permiten resolver problemas relacionados con el reconocimiento de formas o patrones, predicción, codificación, control y optimización. Las redes neuronales pueden ser clasificadas en redes estáticas y dinámicas.

**a) Red neuronal estática.-** Las redes estáticas (feedforward) no tienen elementos de realimentación y no contienen retardos; las salidas son calculadas directamente de la entrada a través de conexiones feedforward, mediante algoritmos backpropagation.

El diseño piloto de la RNA está basado en este tipo de red, tomando como entrada, sólo patrones calendario tal como se muestra en la figura 07, sin embargo éste diseño tuvo que ser cambiado debido a las continuas paradas y fluctuaciones que se dieron en la planta de la fundición.

Figura 07 - Arquitectura de red estática feedforward



Fuente y elaboración propias

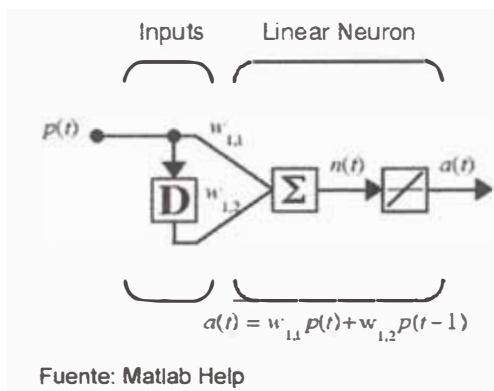
Esta red tiene un sólo patrón de entrada (calendario) cuyas entradas se ponderan con la matriz de pesos  $IW^{1,1}$  para conectarse con las neuronas de la primera capa; asimismo, se considera un umbral  $b^1$  en esta capa para establecer el desplazamiento de la función de activación  $a^1 = \text{tansig}(wp+b)$  en la primera capa de neuronas. Luego, se pasa a la segunda capa de neuronas a través de la matriz de pesos  $LW$ , en la cual se fija el umbral de esta segunda capa  $b^2$ , generándose un escalar  $n^2$  y la correspondiente función de salida  $a = \text{purelin}(wp+b)$ .

**b) Red neuronal dinámica.-** En las redes dinámicas, las salidas no solo dependen de la entrada actual de la red, sino también de las anteriores, así como de las salidas actuales y anteriores o estados de la red. Las redes dinámicas pueden ser clasificadas en dos tipos:

- Las que solo tienen conexiones feedforward (ver figura 08), y
- Las que presentan realimentación o conexiones recurrentes (figura 09).

En la figura 08, la función de entrada  $p(t)$  se conecta a la neurona a través de la matriz de pesos ( $IW_{1,2}$ ), considerando un retardo como una entrada adicional, estableciéndose una función escalar  $n(t)$ ; asimismo, se debe fijar un umbral para establecer el desplazamiento de la función de activación  $a(t) = w_{1,1}p(t) + w_{1,2}p(t-1)$ , que finalmente determinará la salida de la red.


Figura 08 - Red dinámica feedforward





En la figura 09, la red dinámica se realimenta con la salida de la red, convirtiéndose de esta manera en una entrada más. En este caso las demandas pronosticadas, reingresan a la red neuronal, con un retardo predefinido en el modelo de programación.

Figura 09 - Red dinámica con realimentación



Fuente: Matlab Help

Algunas ventajas de las redes dinámicas son las siguientes:

- Las redes dinámicas se adaptan mejor a predicción y aproximación que las redes estáticas.
- Sin embargo, las redes dinámicas son más difíciles de entrenar que las redes estáticas, debido al gran costo computacional que necesitan.
- Debido a que las redes dinámicas tienen memoria, pueden ser entrenadas para aprender características secuenciales o de variación de tiempo.

Las redes dinámicas son entrenadas de manera más efectiva, utilizando los mismos algoritmos, basados en gradiente, que para las redes estáticas; sin embargo - a pesar de que estas redes pueden ser entrenadas, utilizando los mismos algoritmos backpropagation, que las redes estáticas - los rendimientos pueden llegar a ser muy diferentes, porque la gradiente debe ser calculada de una manera más compleja.

El primero es el efecto directo, pues un cambio en los pesos presenta un cambio inmediato en la salida en el tiempo actual (el primer efecto se puede calcular utilizando los algoritmos backpropagation estándares). El segundo es un efecto indirecto, debido a que algunas de las entradas de la capa, tales como  $a(t-1)$ , son además funciones de los pesos.

**c) Redes NARX.**- Las redes NARX (nonlinear autoregressive network with exogenous inputs) son redes dinámicas recurrentes con conexiones de realimentación. Estos modelos presentan cierto retardo tanto en el vector de entrada como en el de realimentación. Se usan principalmente para modelar series temporales, que no pueden desarrollarse con redes estáticas o redes dinámicas simples. Es una clase importante de sistemas de tiempo discreto no lineal, que se puede representar matemáticamente como:

$$y(t+1) = f[y(t), \dots, y(t-q+1); \\ u(t), u(t-1), \dots, u(t-q+1)]$$

Donde  $u(t) \in \mathfrak{R}$  e  $y(t) \in \mathfrak{R}$  representan la entrada y la salida del modelo con tiempo discreto  $t$ ; sin embargo, se puede denotar en su forma vectorial, como:

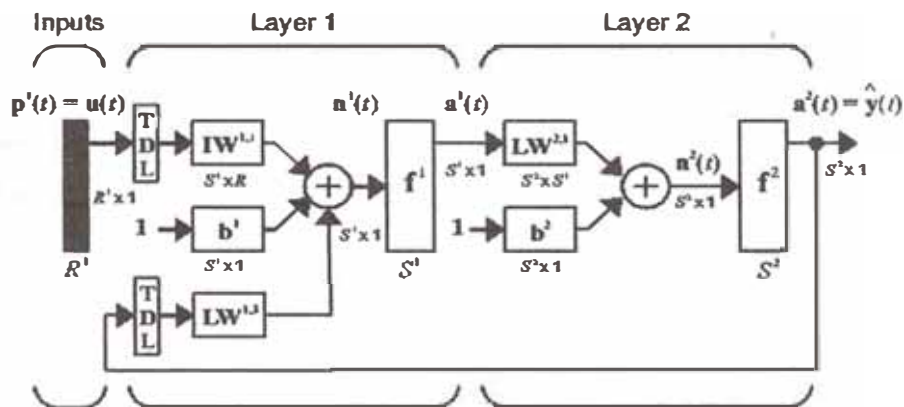
$y(t + 1) = f[u(t), y(t)]$ ; donde los vectores  $u(t)$  e  $y(t)$  representan los regresores de entrada y salida respectivamente.

En la figura 10, se aprecia un modelo simple de red NARX con 02 capas. Las entradas  $p^1(t)$  contienen  $R^1$  elementos que forman vectores  $R^1 \times 1$ , a cuyos elementos se les aplican tiempos de retardo (Time Delay Line Memory) de  $q$  unidades, y se ponderan con la matriz de pesos  $(IW^{1,1})$ , que tiene un arreglo  $S^1 \times R$ , donde  $S^1$  es el número de neuronas de la primera capa. Asimismo, se ingresa el valor del umbral  $b^1$  para establecer el desplazamiento de las funciones de activación  $f^1$  de tipo  $a^1$ .

Por otro lado, la salida  $y(t+1)$  con un vector  $(S^2 \times 1)$ , que realimenta la red - incluyendo un tiempo de retardo  $q$  dirigido a la matriz de pesos  $(LW^{1,3})$  - se incorpora como elemento para el cálculo del escalar  $n^1(t)$

Posteriormente, se pasa a la segunda capa mediante las funciones de activación  $f^1$  de tipo  $a^1(t)$  con un arreglo vector  $S^1 \times 1$ , que se conecta a las neuronas de la segunda capa a través de la matriz de pesos  $(LW^{2,1})$ , incluyendo los umbrales de dicha capa  $b^2$  con arreglo vector  $S^2 \times 1$ . La resultante es un escalar de la forma  $n^2(t)$ , que determina la salida de la red a través de la función  $f^2$  del tipo  $a^2(t) = \hat{y}(t)$ .

Figura 10 - Arquitectura de RNA dinámicas recurrentes NARX simple

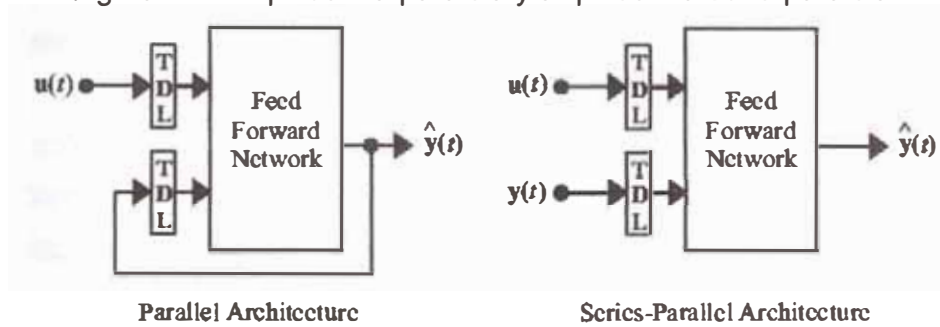


Fuente: Matlab Help

El entrenamiento de las redes NARX se da en dos etapas. El entrenamiento con una red de arquitectura paralela (figura 10), cuya data real de salida en ese momento se considera como entrada adicional.

El cambio y entrenamiento con la arquitectura en serie, en donde se elimina la entrada anterior, para colocar el estimado de este momento con el mismo retardo que en la arquitectura serie-paralela (figura 11).

Figura 11 - Arquitectura paralela y arquitectura serie-paralela



Fuente: Matlab Help

Este procedimiento permite realizar una predicción óptima, pues en el futuro la realimentación se realizará con los valores estimados, de los cuales no se tiene ninguna referencia.

Consta habitualmente de tres capas de unidades elementales o neuronas:

- i) **Capa de entradas.-** Las neuronas de esta capa servirán para introducir las variables de entrada del modelo.
- ii) **Capa intermedia u oculta.-** Sus unidades combinan las entradas de la capa inicial a partir de parámetros o ponderaciones denominadas conexiones o pesos sinápticos en términos neuronales que se van ajustando a lo largo del proceso de entrenamiento de la red.
- iii) **Capas de salida.-** Proporciona las estimaciones de la red.


**d) Entradas o patrones.-** Uno de las tareas más difíciles para la construcción de un buen modelo de red neuronal es la selección y clasificación de los patrones óptimos, así como la recolección de dicha información.

Una serie de investigaciones realizadas sobre la demanda eléctrica y sus determinantes (P.Murto (1998), J.Bao (1996), Proyecto Indel (1998)) en diferentes países, han permitido identificar un conjunto de variables básicas que explica la evolución de la demanda eléctrica a lo largo del tiempo, siendo este conjunto común para la mayor parte de los países desarrollados.

e) **Funciones de activación.-** Las principales funciones de activación o funciones de transferencia neuronal, se clasificaron en tansig, logsig y purelin.

La función tansig es una función tangente hiperbólica sigmoideal, cuyo rango está comprendido entre -1 y 1. La función logsig, es una función logarítmica sigmoideal que con rango entre 0 y 1. La función purelin, es una función de transferencia lineal donde la entrada es igual a la salida.

Figura 12 - Principales funciones de activación RNA



$$a = \text{tan sig}(n) = \frac{2}{(1 + e^{-2n}) - 1}$$

$$a = \text{log sig}(n) = \frac{1}{1 + e^{-n}}$$

$$a = \text{purelin}(n) = n$$

Fuente: Matlab Help

f) **Herramientas de computación para redes neuronales.-** Existen simuladores de redes neuronales tales como:

- Brain Maker
- Neuronal Works
- NeuroSolutions
- Simulink en Matlab

Estos programas están dotados de entornos gráficos de manejo intuitivo y simulan muchos modelos neuronales clásicos.

**2.2.2 Control de demanda.-** Tiene como objetivo alisar las curvas de la carga horaria; es decir, evitar que se presenten picos de máxima demanda. Esta máxima demanda es la potencia acumulada en un período que generalmente

es de entre 8 y 30 minutos.

Según la Comisión de Energía para el Ahorro de Energía (CONAE), *“controlar la demanda es la acción de interrumpir por intervalos de tiempo la operación de ciertas cargas eléctricas (iluminación, motores, etc.) que inciden directamente sobre la demanda máxima facturable, a fin de reducir o limitar los niveles de consumo en razón de los precios tarifarios”*.

Este control puede representar una oportunidad de ahorro económico, pues el cargo por demanda es un componente importante de la facturación eléctrica; además, el ahorro no será tan sólo por la disminución en el cargo en la demanda, sino también en los cargos por consumo en el horario punta.

El período más habitual en la gran mayoría de países es de 15 minutos. Esta potencia es calculada por el maxímetro, el cual registra el mayor valor de un mes, que se factura.

Hay distintas formas para calcular la máxima demanda:

- **Ventana fija (Fixed or block demand).**- La empresa suministradora de energía proporciona cada período un impulso para sincronizar el inicio del período de la máxima demanda.
- **Ventana deslizante.**- No hay impulso de sincronización, por eso se toman siempre los últimos 15 min (si el período es 15 min). Cada segundo se actualiza el valor con los últimos 15 min.
- **Ventana sincronización de tiempo.**- Es una variante de la ventana fija. La empresa suministradora proporciona un impulso de sincronización al inicio del día que indica el inicio del primer período. A continuación, y el resto del día, las sincronizaciones de cada período ya no las da la compañía eléctrica sino el propio reloj del equipo. Al final del día habrá un nuevo impulso de la compañía que permitirá reajustar el reloj del equipo con el de la compañía.

El control de demanda se aplica sobre la base de un censo de cargas

eléctricas que operan en período punta o en espacios de tiempo que influyen en la demanda punta de la planta o industria, identificándose equipos que pueden ser desconectados en estos intervalos de tiempo, así como las posibles causas de excesos de demanda históricas. Para ello, se revisan, asimismo, las facturaciones históricas de energía eléctrica y datos de producción para establecer un modelo de control de demanda que no afecte la actividad productiva de la planta.

**a) Componentes de control de demanda.-** La unidad básica tiene los siguientes componentes principales:

- Transformadores de corriente, para proveer una señal de entrada desde el suministro de la Comisión Federal de Electricidad al controlador de demanda.
- Transductores, para convertir la señal de entrada en Watts a una señal en milivolts para el panel lógico.
- Controlador de demanda, para monitorear los niveles de potencia a la entrada y actuar cuando éstos se aproximen al nivel pico de la demanda preseleccionada.
- Panel relevador, para mandar señales de control a las cargas conectadas; el panel lógico manda señales a éstos relevadores de corriente los cuales en su momento, controlan el equipo.

Las unidades más sofisticadas añaden varios parámetros comunes, para ofrecer un equipo más poderoso y versátil:

- Controles de reloj, que se usan para rotar la selección de varias cargas sobre una base de tiempo, y también para controlar el tiempo máximo de una carga apagada.
- Programador de ciclos de trabajo, para determinar los tiempos y períodos del ciclo de apagado de una carga durante diferentes horas de operación
- Programador de la hora del día, que añade la posibilidad de apagar equipos independientemente de la demanda.

- Equipos diversos como son; sensores, analizadores, fuente externa de alimentación, memorias de estado sólido, características de todo el equipo electrónico de control de demanda y de adquisición de datos.

**b) Tipos de control de demanda.-** Existe una gran variedad de controladores de demanda disponibles, con diferentes grados de sofisticación, complejidad y costo. Por tal motivo, los sistemas de control se han clasificado en dos tipos:

- Controles manuales de encendido y apagado.
- Controles automáticos programables e inteligentes.

**c) Estrategias de control.-** Para establecer programas que limiten la demanda máxima es necesario identificar las cargas que generan dichos picos de demanda, así mismo, determinar el tiempo y el horario en que ocurren los picos de demanda.

El siguiente paso es determinar la magnitud de la carga para poder tomar la decisión de restringir o diferir la operación de las cargas y contribuir así con la reducción de la demanda pico y la facturación eléctrica.

Ciertamente, los sistemas de calefacción, aire acondicionado, iluminación, motores, y otros sistemas de cargas no necesarias pueden ser desconectados parcialmente, o bien pueden ser desconectados unos cuantos minutos en el período dónde ocurre la demanda pico. Por tanto, entre las principales estrategias que se deben considerar para llevar a cabo un control de los equipos son las siguientes:

- Tiempos y horarios de operación y desconexión.
- Días festivos.
- Monitoreo de la demanda.

La acción de encendido y apagado de los equipos pueden realizarse a través de mecanismos muy simples como un temporizador (timer) conectado al interruptor de la carga, o por medio señales enviadas por un sistema de control

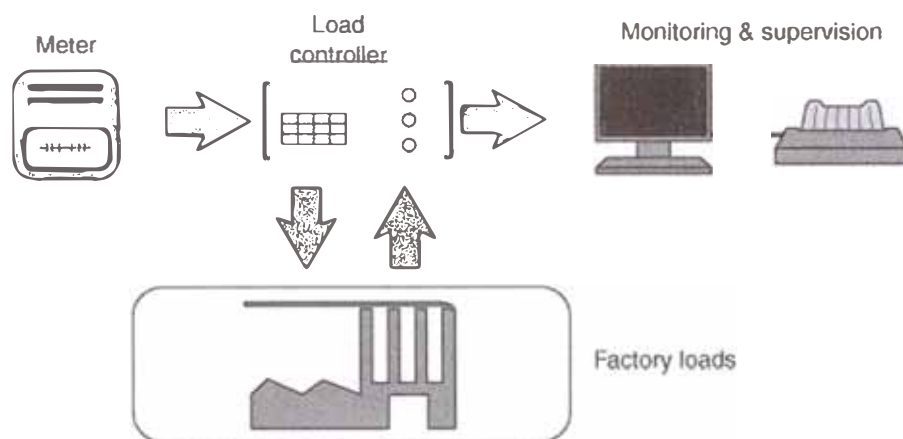


automático.

Un sistema de control de la demanda eléctrica permite manejar la operación de un conjunto amplio de equipos de manera que se utilice la menor cantidad de energía posible en el período "punta" ó, en su caso, mover cargas que operan en horas pico de demanda a los horarios huecos de un mismo período (Figura 13).

Los sistemas de control de la demanda se componen de varios elementos: sensores, que registran si un aparato está encendido o apagado o si se encuentra en un régimen de operación cuando existen más de dos opciones; un sistema de comunicación que permite intercambiar señales con un punto central; un microprocesador (o computadora) que recibe las señales, procesa la información y envía señales a los equipos para que actúen de acuerdo a un programa preestablecido; y un conjunto de actuadores, que operan los equipos de acuerdo a las señales enviadas.

Figura 13 - Elementos de control de demanda



Fuente y elaboración: Electric Load Management, European Copper Institut

El control de demanda es un mecanismo para no superar el límite de máxima potencia contratada. Para ello, se procede a la desconexión de cargas que el proceso de trabajo permita.

Las posibles cargas a desconectar son:

- Luces
- Compresores
- Aires acondicionados
- Bombas
- Ventiladores y extractores
- Embaladoras
- Trituradoras

En general todas aquellas máquinas que no afecten el proceso principal de producción o que no son esenciales. Además un modelo de control de la demanda eléctrica es altamente indicado en aquellos procesos cuya operación tiene fuertes variaciones en la demanda máxima y bajos factores de carga, como son empresas relacionadas con la fundición, minería, automotriz, textil, papeleras, etc.

Existen 2 maneras de evitar exceder la máxima demanda:

- **Preventivo.**- El método preventivo es el adecuado para aquellas empresas que no quieren permitir la conexión o desconexión automática de cargas. El sistema previene mediante unas alarmas visuales o auditivas, cuando se va a superar la potencia contratada para que un operario manualmente desconecte unas determinadas cargas.
- **Predictivo.**- El método predictivo es el método más habitual e inteligente. Hace una previsión de lo que va a suceder al final del período y optimiza las cargas para, por un lado, tener cuantas más cargas conectadas mejor, pero siempre sin exceder el límite máximo que se haya programado.

Este sistema es obviamente sólo para las demandas en ventana fija o ventanas con sincronización.

Para su implementación, es necesaria la medición de la potencia instantánea, y calcular de una manera automática si la potencia usada va a exceder la contratada. De tal forma que de una manera rápida y fiable pueden desconectar las cargas que se requiera mediante los relés incorporados en los equipos.

Estos equipos deben albergar las distintas tarifas, y así realizar un control aún más preciso de su instalación según la tarifa que se tenga contratada.

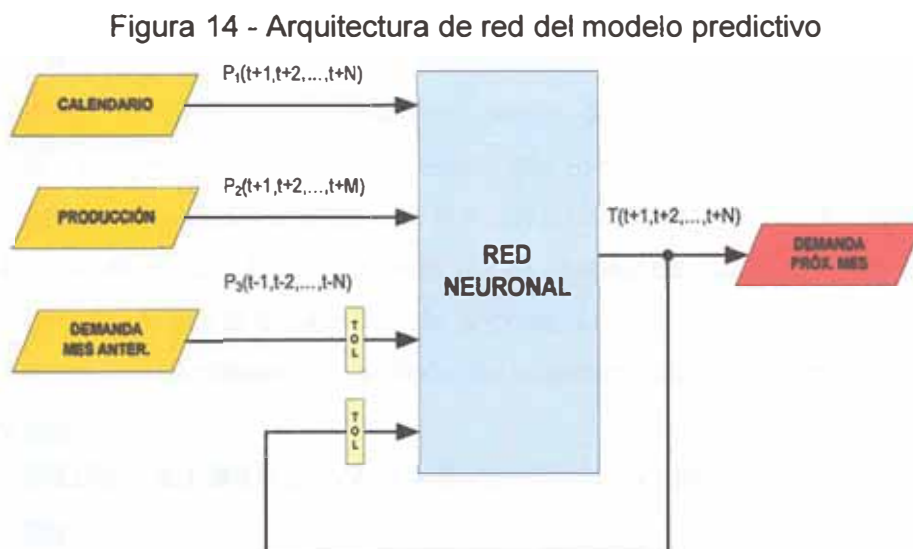
## CAPÍTULO III

### PROGRAMA DE CONTROL DE DEMANDA

Considerando el marco teórico, se eligió la red neuronal dinámica recurrente (feedback) NARX modificada, por su gran capacidad para predecir el comportamiento de series temporales, como el caso de la demanda eléctrica [Hava T. Siegelmann, Computational capabilities of recurrent NARX neural networks (1997)].

#### 3.1 Arquitectura de red del modelo predictivo:

En la figura 14, se presenta la arquitectura de red del modelo predictivo basada en una estructura neuronal dinámica NARX modificada, que incluye las entradas (patrones), capas, neuronas necesarias y salidas.



Fuente y elaboración propias

**3.1.1 Patrones de entrada.-** Los factores que influyen directamente en la demanda eléctrica son: calendario, producción, demanda anterior y temperatura. Sin embargo, debido a la dificultad de contar con valores exactos de la temperatura, sólo se consideraron los tres primeros patrones de entrada para la red neuronal del modelo de predicción, que se presentan en la tabla 04.

Tabla 04 - Factores considerados en la red neuronal

Patrones de entrada	Unidades	Tipo	Rango
<b>1. Calendario</b>			
1.1. Cuarto de hora		Categorica(codificada)	0 - 3
1.2. Hora		Numérica(valor real)	0 - 23
1.3. Día		Categorica(codificada)	0 - 6
1.4. Semana		Categorica(codificada)	0 - 4
1.5. Mes.		Categorica(codificada)	0 - 11
<b>2. Producción</b>			
2.1. Anodos	TM/h	Numérica (valor real)	
2.2. Acido	TM/h	Numérica (valor real)	
2.3. Oxígeno	TM/h	Numérica (valor real)	
<b>3. Demanda anterior</b>			
3.1. Demanda mes anterior	MW	Numérica (valor real)	

Fuente y elaboración propias

Estos elementos  $p_i(t)$  de los patrones de entrada han sido ordenados vectorialmente para alimentar a la red y aproximar la función de salida, de acuerdo al siguiente detalle:

- **Calendario.-** Es un arreglo de vectores de  $5 \times N$  elementos, donde 5 es el número de patrones calendarios: cuarto de hora, hora, día, semana y mes, y N es el número de muestras por mes, teniendo como período de muestreo cada 15 minutos, con  $N = 2976$  (31 días) ó  $N = 2880$  (30 días).
- **Producción.-** Será un vector de  $3 \times M$  elementos, donde 3 es el número de patrones como producción de ánodos, ácido sulfúrico y oxígeno y M el número de muestras con período de muestreo de 1 día, con  $M=2880$  (30 días).
- **Demanda del mes anterior.-** Será un vector de  $1 \times N$ , como único patrón.

Un ejemplo de la data obtenida en su forma original y en su nueva escala [0, 1], se presenta en la tabla 05:

Tabla 05 - Tratamiento de la data de entrada

Información de entrada en su forma original								
1/4 hora	Hora	Día	Sem.	Mes	Ánodos(TM/h)	Oxígeno(TM/h)	Ácido(TM/h)	Demanda(t-1)
1	0	2	3	4	27099	1012.15	33252	30
Información de entrada en nueva escala								
0.33	0	0.33	0.75	0.36	0.677	0.86309	0.738	1

Fuente y elaboración propias

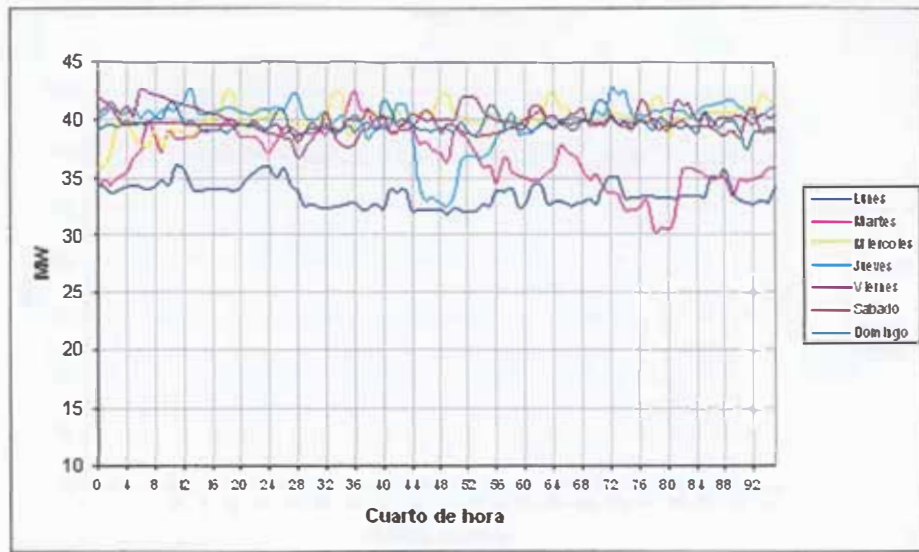
Para la normalización, las variables consideradas en el modelo han sido linealmente escaladas (linear scaling) entre 0 y 1. Este procedimiento consiste simplemente en modificar la escala de las variables atendiendo a su valor mínimo y máximo para obtener series más homogéneas.

Tomando en cuenta los patrones descritos anteriormente y las muestras de data histórica de la demanda eléctrica en la fundición de Ilo, se procedió a evaluar la influencia de los patrones antes mencionados en el comportamiento de la demanda.

#### a) Calendario:

**a.1) Cuarto de hora.-** Este patrón es el promedio de las lecturas de demanda (MW) tomadas cada cuarto de hora, considerando una muestra de 1344 datos entre el lunes 18 de junio y el domingo 01 de julio del 2007 (96 cuartos de hora por día), para observar la variación de la demanda eléctrica (MW) de fundición de Ilo en dichos períodos de tiempo (figura 15).

Figura 15 - Demanda cada 15 minutos (18 al 24 -06-07)

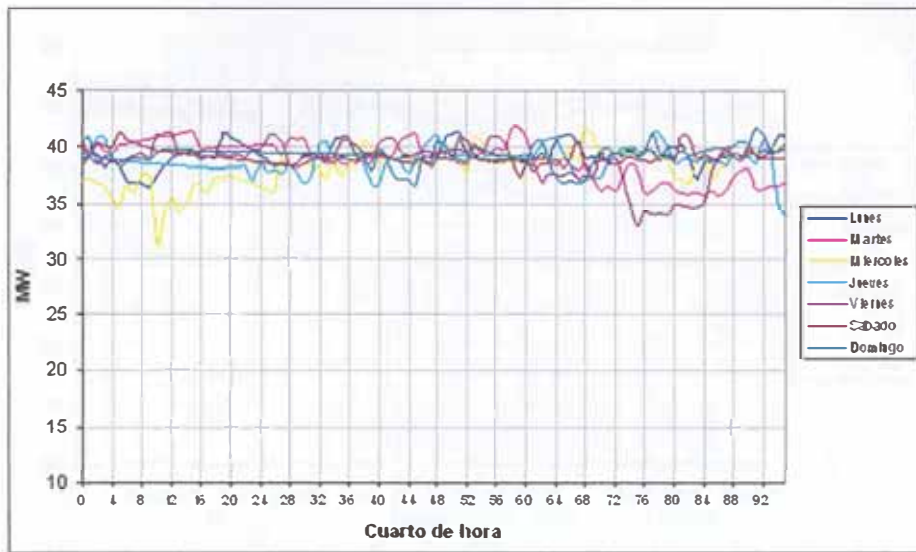


Fuente: Servidor IION

Elaboración: Propia

Cada día de la semana presenta cierta periodicidad dependiendo del cuarto de hora muestreado. Este comportamiento se presenta, sobre todo los días lunes y miércoles (ver figura 16). Se pudo concluir que el cuarto de hora es un patrón necesario para el desarrollo de la RNA y por ende del módulo de predicción.

Figura 16 - Demanda cada 15 minutos (25-06-07 a 01-07-07)



Fuente: Servidor IION


Elaboración: Propia

**a.2) Hora del día.-** La hora del día influye en la curva de demanda eléctrica de una ciudad, debido a que en horas punta, como las 3 de la tarde, por ejemplo, el consumo es mayor. Sin embargo en el ambiente industrial donde la demanda eléctrica no debe sufrir cambios significativos no se notó una tendencia clara de subida-bajada; sin embargo, se apreció una serie de oscilaciones en ciertos períodos asemejándose la curva a una función sinusoidal.

En la figura 17, se presenta el comportamiento de la demanda horaria de la fundición de Southern Peru.



Figura 17 - Demanda cada hora (18 al 24-06-2007)




Fuente: Servidor IION

Elaboración: Propia

Sin embargo en la figura 18, correspondiente a la semana siguiente, ya se pudo observar una cierta periodicidad a las 9, 11, 14 y 19 horas (ver figura 24).

Figura 18 - Demanda cada hora (25-06-07 al 01-07-07)




Fuente: Servidor IION

Elaboración: Propia

**a.3) Día de la semana.-** El día de la semana influye de gran manera en el comportamiento de la demanda, pues si es un día programado para colada, y a su vez todos los demás procesos no dejan de funcionar, la demanda media y máxima se verán incrementadas.

**a.4) Semana.-** Para este estudio, se tomaron la demanda media y máxima diaria durante un período de 10 semanas, comprendidas entre el 23 de abril al 01 de julio del 2007, cuyos resultados se presentan en las figuras 19 a 22.

Figura 19 - Demanda media semanal (23-04-07 al 01-07-07)



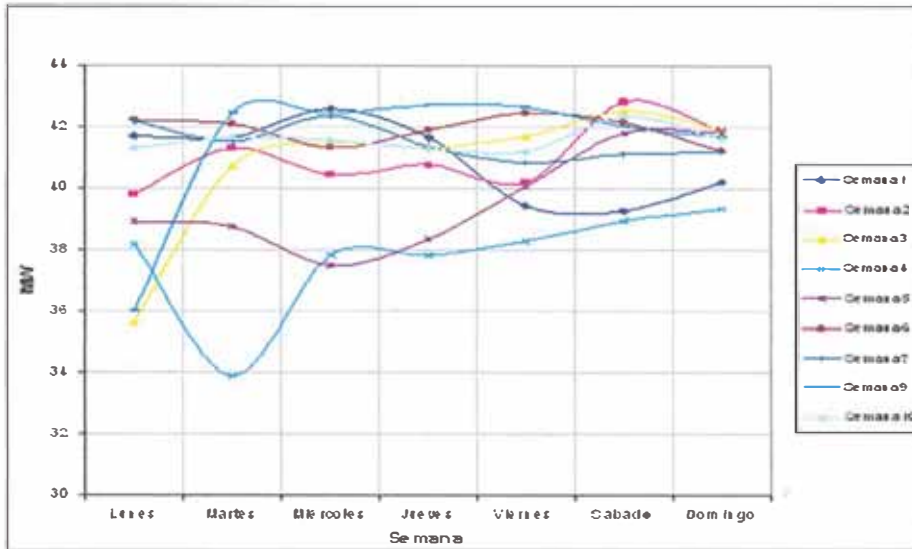
Fuente: Servidor IION  
Elaboración: Propia

**a.5) Mes.-** La demanda varía en función del mes de análisis, pues no es lo mismo un mes de verano que otro de invierno.

En las figuras 19 y 20, no se observa ninguna relación precisa tanto en la demanda media semanal, así como en la demanda máxima semanal, por lo que se concluye, que los días - vistos de manera continua por semana - no presentan gran influencia en la demanda; sin embargo, al apreciarse las semanas de manera continua, como en los figuras 21 y 22, se observó, sobre todo en el caso de la demanda máxima, que dependiendo de los días, la curva

sigue cierta periodicidad, convirtiendo a éste factor sea uno de los más importantes para el análisis.


Figura 20 - Demanda máxima semanal (23-04-07 al 01-07-07)



Fuente: Servidor IION

Elaboración: Propia

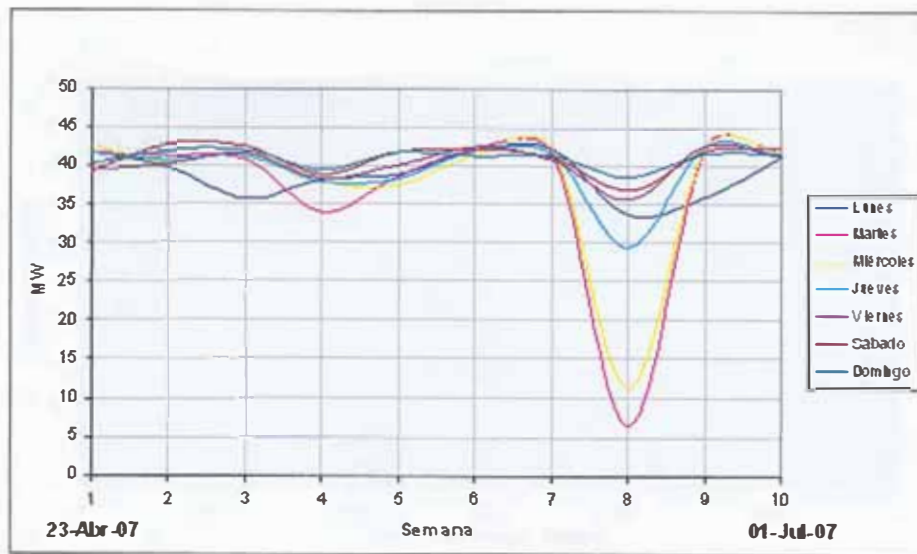
Figura 21 - Demanda media diaria (23-04-07 al 01-07-07)



Fuente: Servidor IION

Elaboración: Propia

Figura 22 - Demanda media diaria (23-04-07 al 01-07-07)



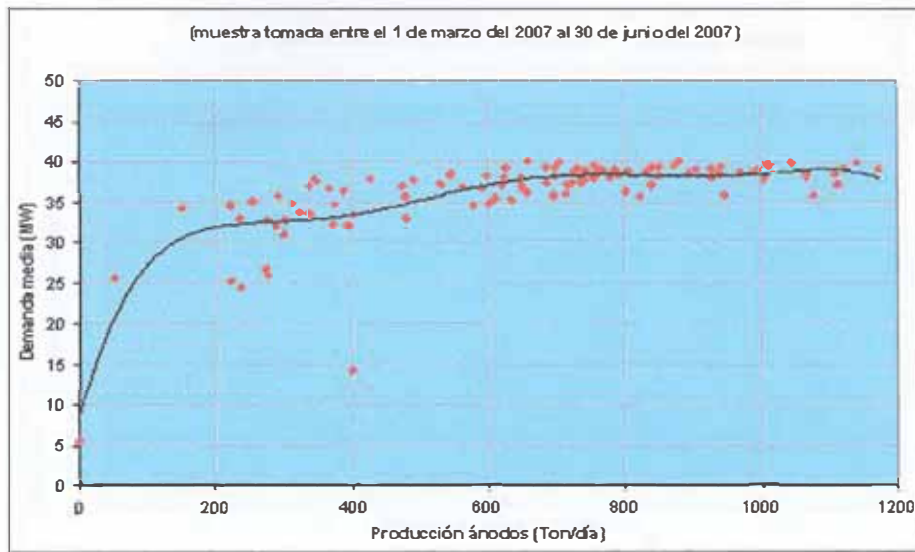
Fuente: Servidor IION

Elaboración: Propia

**b) Producción.-** La producción es un factor imprescindible en el ambiente industrial, pues dependiendo de ésta y sus estimados se presupuestan los cargos por concepto de insumos, combustibles, electricidad y demás. Por lo tanto éste es un parámetro principal en nuestro análisis.

**b.1) Producción de ánodos.-** Se comparó la producción diaria, versus la demanda media y máxima, día a día, entre marzo y junio del 2007. Los resultados muestran que la curva de demanda media diaria varía de manera proporcional a la producción diaria de ánodos de cobre, siguiendo una tendencia cuasi logarítmica (ver figura 23).

Figura 23 - Producción de ánodos vs. demanda media




**Fuente:** Reporte de producción Planta de ánodos.

**Elaboración:** Propia

En la figura 24, se aprecia que la demanda máxima diaria sigue casi la misma tendencia que la media. Los valores estimados de producción son básicos en la predicción.

Figura 24 - Producción de ánodos vs. demanda máxima



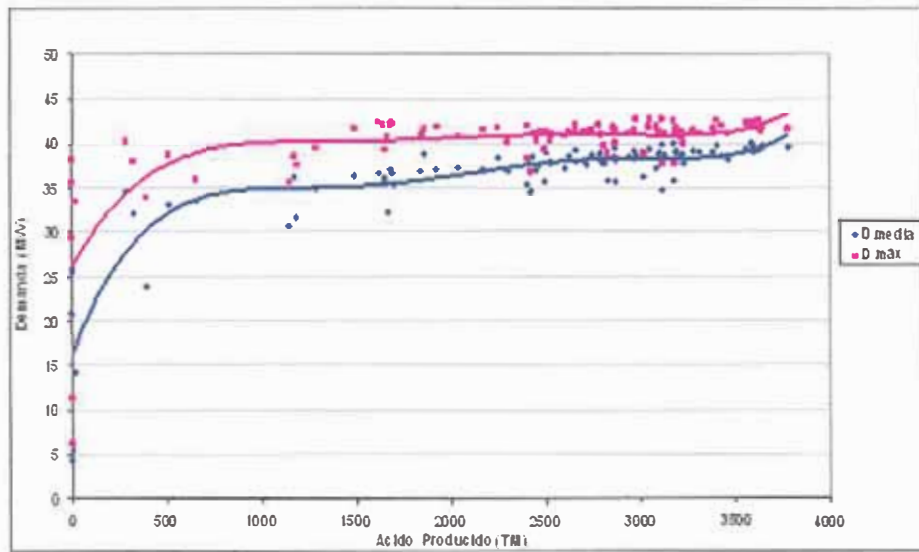
Fuente: Reporte de producción Planta de ánodos.

Elaboración: Propia

## b.2) Producción de ácido sulfúrico:

Considerando que es otro de los productos de la fundición y el resultados de 2 de las plantas de mayor consumo eléctrico (Plantas de Ácido 1 y 2), éste patrón fue considerado dentro del patrón producción (ver figura 25).

Figura 25 - Producción de ácido sulfúrico vs. demanda media y máxima



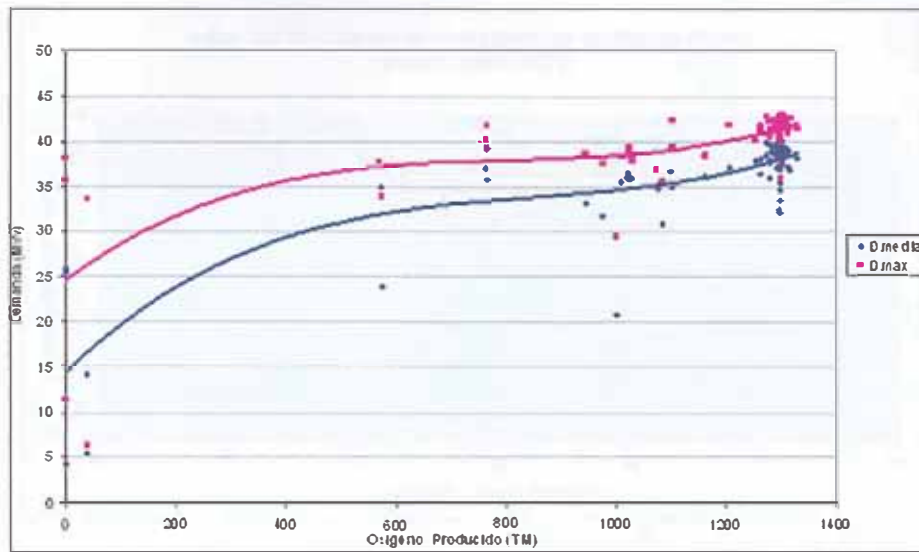
Fuente: Reporte de producción Planta de ácido

Elaboración: Propia

### b.3) Producción de oxígeno:

Debido al gran consumo de las plantas de oxígeno 1 y 2, su influencia en producción se hizo imprescindible para el modelo (ver figura 26).

Figura 26 - Producción de oxígeno vs. demanda media y máxima



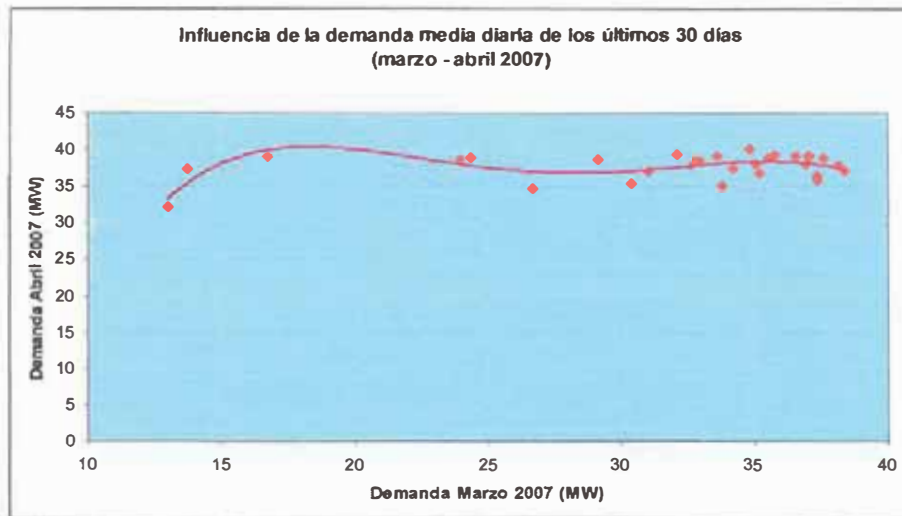
Fuente: Reporte de producción Planta de ácido

Elaboración: Propia

c) **Demanda anterior.**- Asimismo, se realizaron estimaciones futuras, basándose en los últimos valores obtenidos. A su vez el modelo desarrollado, también incluyó la demanda eléctrica del último mes (ver figura 27).




Figura 27 - Influencia de demanda media diaria de marzo en abril del 2007



Fuente: Servidor ION

Elaboración: Propia


Figura 28 - Influencia de demanda media diaria de abril en mayo de 2007



Fuente: Servidor ION

Elaboración: Propia

Figura 29 - Influencia de demanda media diaria de mayo en junio del 2007




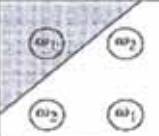



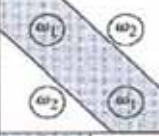
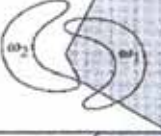


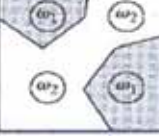
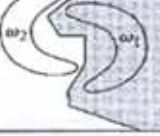

Fuente: Servidor ION

Elaboración: Propia

**3.1.2 Capas de la red neuronal.-** No existe una metodología específica para determinar el número de capas ocultas en una red neuronal artificial; sin embargo, existen ciertos criterios acerca de su impacto en la red. Se conoce que cuando el número de capas aumenta, la identificación en el espacio  $R^2$  se hace más precisa; sin embargo, en el espacio  $R^N$  con  $N > 3$ , la precisión no necesariamente aumenta al tener un mayor número de capas ocultas [3].

En este caso, basándose en las investigaciones de modelamiento de sistemas dinámicos complejos propuestos por Meisenbach, se consideraron inicialmente 2 capas ocultas, hasta llegar a 3 capas, que permitió mejorar la predicción con un costo computacional de entrenamiento aceptable (ver figura 30).

Figura 30 - Influencia del número de capas en las RNA

Network structure	Type of decision region	Solution to exclusive-OR problem	Classes with meshed regions	Most general decision surface shapes
Single layer 	Single hyperplane			
Two layers 	Open or closed convex regions			
Three layers 	Arbitrary (complexity limited by the number of nodes)			

Fuente: Digital Image Processing - González y Woods 2da Edición

**3.1.3 Número de neuronas por capa.-** Inicialmente, se han utilizado 16 neuronas en la primera capa oculta y 8 neuronas en la segunda. Se ha considerado esta cantidad de neuronas porque la computadora presentaba mejor rendimiento con un número de neuronas que fuera potencia de 2.

Asimismo, se han introducido líneas de retardo para los valores de demanda estimada y del mes pasado, pues el valor presente de demanda está directamente relacionado con los últimos 2 valores muestreados.

La determinación del número óptimo de neuronas de las capas ocultas, se ha llevado a cabo mediante un proceso de ensayo y error. En todo caso, el objetivo ha sido dotar a la red de un número adecuado de neuronas en la capa oculta para que fuera capaz de aprender las características de las posibles relaciones existentes entre los datos de la muestra.

Demasiadas neuronas causaron un sobre-ajuste, la red memorizó el conjunto de datos de entrenamiento y para dichos valores su precisión fue casi absoluta. Sin embargo, ante valores desconocidos, ésta falló estrepitosamente. Por otra parte, al reducirse el número de neuronas en la capa oculta, se llegó a

una situación de sub-ajuste, en la cual la red no fue capaz de aprender ciertas relaciones existentes entre las variables.

Las principales funciones de activación o funciones de transferencia neuronal utilizadas fueron: tansig, logsig, y purelin.


La determinación del número adecuado de neuronas de las capas ocultas se ha llevado a cabo mediante un proceso de ensayo y error hasta que la red fuera capaz de aprender las características de las posibles relaciones existentes entre los datos de la muestra.

Se pudo comprobar que demasiadas neuronas llevan a un *sobre-ajuste*, logrando una precisión casi absoluta para valores pertenecientes al conjunto de datos de entrenamiento; sin embargo, al presentarse valores desconocidos falló estrepitosamente, como consecuencia del sobre-ajuste, siendo incapaz de *generalizar*. Por otra parte, cuando el número de neuronas en la capa oculta se redujo, se llegó a una situación de *sub-ajuste*, en la cual la red no fue capaz de aprender ciertas relaciones existentes entre las variables [ ].

En el presente caso y por experiencia de modelamiento de sistemas dinámicos complejos, se utilizaron **16 neuronas en la primera capa oculta y 8 neuronas en la segunda**. La cantidad de neuronas descritas respondió a la mejor performance de la PC, cuando trabajaba con neuronas cuyo número fuera potencia de 2.

Los retardos en el caso de nuestro modelo neuronal dinámico recurrente, hacen que el dato de ingreso no sólo dependa de variables externas, sino también, de sí mismo en períodos pasados. En nuestro caso se van a colocar TDL (líneas de retardo) a los valores de demanda, tanto la estimada, así como a la demanda del mes pasado, debido a que se demuestra que el valor presente de demanda está directamente relacionado con los últimos 2 valores muestreados.

Figura 31 - Representación de una TDL en tiempo discreto



Fuente: Matlab Help

Sin embargo y por capacidad computacional, se tomaron inicialmente 2 retardos en cada TDL, pudiendo este valor variar de acuerdo a los experimentos y simulaciones posteriormente realizadas.

**3.1.4 Salidas o targets.-** De acuerdo al objetivo del modelo predictivo, las salidas fueron:


**a) Demanda del mes próximo.-** Es un vector de  $1 \times N$ , en donde  $N$  es el valor de demanda pronosticada de un mes futuro; es decir, en diciembre de un año, se puede calcular la demanda de energía eléctrica de los meses de enero a diciembre del año siguiente. Por ejemplo para setiembre de 2007, la demanda predicha fue 42,089 kW.

**b) Consumo del mes próximo.-** Es un valor ( $1 \times 1$ ) obtenido directamente de la data de demanda pronosticada, considerando el algoritmo base de la facturación mensual. Así el consumo calculado para el mismo mes de octubre de 2007 fue 29,239.64 kWh.

**3.1.5 Funciones de activación.-** En este modelo, se han elegido las funciones 'tansig' para las 2 capas ocultas (incluida la capa de entradas), debido a que el incremento se realizó de manera amortiguada en la zona de cambio para la demanda muestreada. Para la función de salida se ha elegido la función 'purelin', ya que ésta es la que escala directamente a la salida en MW.

Una vez definida el tipo de RNA a utilizar (dinámica recurrente), así como sus patrones y parámetros, se procedió a diseñar la nueva arquitectura de la RNA. A continuación se muestra el diagrama detallado de esta arquitectura, considerando todos los enlaces y realimentaciones.

Figura 32 - Arquitectura final de la RNA



Fuente y elaboración propias

### 3.2 Programación de la red neuronal:

En la figura 33, se presenta el diagrama de flujo de la programación de la red neuronal. Inicialmente, se realizó la adquisición de datos para su posterior filtrado y selección. Estos datos fueron, luego, acondicionados para definir las características de la red neuronal y facilitar su creación. Luego, se definieron los parámetros de la red neuronal para el entrenamiento de la red neuronal y acceder a los resultados probables. Cuando estos resultaron menores a 2%, entonces pasaron a la validación con valores reales en los períodos de análisis de estudio; sin embargo, cuando el error superó el umbral de 2%, se regresaba a la etapa de definición de características de la red.

Figura 33 - Procesos de programación de la red neuronal



Fuente y elaboración propias

**3.2.1 Adquisición de datos.**- La adquisición de la data para el entrenamiento, se realizó a partir del archivo 'entrenamiento1.txt', que es un arreglo de la data ordenada. Esta data contiene tanto los patrones de entrenamiento, así como las salidas o targets de demanda relacionados a los mismos. La data del archivo de entrenamiento corresponde a los patrones y targets correspondientes a los meses comprendidos entre mayo y julio del 2007, fechas en donde la fundición presenta un comportamiento estable luego de la modernización. La data adquirida está normalizada en el intervalo de [0; 1], debido a que presenta una mejor performance.

El código usado en Matlab es el siguiente:

### **%% *Análisis de la Data***

*% Adquisición de la Data*

```
PT = load('entrenamiento1.txt');
```

*% Patrones del 1 mayo al 31 julio del 2007*

*% Targets del 1 mayo al 31 julio del 2007*

```
P = PT(:, 1:4); % Patrones
```

```
T = PT(:, 5); % Targets
```

Donde:

P: Matriz normalizada en el intervalo [0,1] que contiene los patrones de entrenamiento previamente definidos.

T: Vector normalizado en el intervalo [0,1] que contiene las demandas de entrenamiento registradas.

**3.2.2 Filtrado y selección de datos.**- Para realizar el filtrado de la data, se fijó un umbral equivalente a la media de los datos adquiridos, y se seleccionaron aquellos patrones y targets, cuya demanda fuese mayor a dicho umbral.

El umbral seleccionado fue de 37 000 KW. El código usado es el siguiente:

*% Filtrado de la data*

```
Pn = []; Tn = []; % Vectores filtrados
```

```
for i = 1:length(T)
```

```
    if Ymax*T(i) > 37000
```

```
        Pn = [Pn;P(i,:)];
```

```
        Tn = [Tn;T(i)];
```

```
    end
```

```
end
```



Donde:

$Y_{\max}$ : Demanda máxima registrada en el período de toma de datos.

Pn: Patrones filtrados

Tn: Targets filtrados

**3.2.3 Acondicionamiento de datos.**- Luego, se filtró la data pero se dejaron vacíos los datos eliminados, por lo que el código se modificó, de tal manera que al mismo tiempo que se procedió al filtrado, se realizó el acondicionamiento de los datos vacíos, basándonos en métodos estadísticos, con intervención de la media, la desviación estándar y la periodicidad de los picos.

*% Filtrado y acondicionamiento de la data*

*for i = 1:length(T)*

*if Ymax\*T(i) < 37000*

*T(i) = 1.05\*(m+0.003\*m\*rand(1)) + 0.1\*s\*rand(1);*

*if (i-floor(i/p)\*p) == 0*

*T(i) = 1.005\*T(i);*

*T(i-1) = 1.01\*T(i);*

*T(i-2) = 1.04\*T(i);*

*T(i-3) = 1.04\*T(i);*

*T(i-4) = 1.01\*T(i);*

*T(i-5) = 1.005\*T(i);*

*end*

*end*

*end*

Donde:

m: Demanda media normalizada en el período de toma de datos.

s : Desviación estándar normalizada en el período de toma de datos.

p : Período de aparición de picos de demanda (en cuartos de hora).

**3.2.4 Definición de las características de la red.-** Después de esta etapa, se definieron las características de la red neuronal con sus entradas y salidas, detalladas en el apartado 4.1.

**3.2.5 Creación de la red.-** El siguiente código muestra, el algoritmo para la definición de características de la RNA, como por ejemplo: matriz de máximos y mínimos, número de retardos (delays), número de neuronas, número de capas ocultas y tipo de funciones de activación; así como la creación de la red en sí.

```
%% Creamos la Red Narx
% Definimos vector de máximos y mínimos (no mes)
% semana: 0 - 4
% día: 0 - 6
% hora: 0 - 23
% cuarto: 0 - 15
%PR1 = [0 1;0 1;0 1;0 1;0 1;A(6,:)];
PR1 = [0 1;0 1;0 1;0 1];
PR2 = [0 1];
PR = {PR1,PR2};

d = 2;                                % Número de delays

S1 = 16;                               % Número de Neuronas (MUY IMPORTANTE!!)
S2 = 8;

d11 = [1:d];                           % Delay de 1ra entrada (MUY IMPORTANTE!)
d22 = [1:d];                           % Delay de 2da entrada
narx_net = newnarxsp(PR,d11,d22,[S1 S2 1],...
                    {'tansig','tansig','purelin'});
```

Donde:

$PR_1$ : Matriz de máximos y mínimos (normalizados) de los patrones de entrada.

$PR_2$ : Matriz de máximos y mínimos (normalizados) de los targets de salida.

PR: Estructura de máximos y mínimos para la red Narx.

D: Número de delays.

d11: Vector de delays para los patrones de entrada.

d22: Vector de delays para los targets de salida.

S1: Número de neuronas ocultas de la primera capa.

S2: Número de neuronas ocultas de la segunda capa.

narx net: Red neuronal dinámica Narx.

**3.2.6 Definición de los parámetros de la RNA.-** Los parámetros para el entrenamiento de la RNA NARX son los mismos que para el entrenamiento de una red estática, sin embargo debido al tipo de entrenamiento que se utilizó, el costo computacional sería mucho mayor. Entre los más importantes parámetros para el entrenamiento, se tiene: número de épocas de entrenamiento, meta (goal), gradiente mínima, tipo de entrenamiento, número de épocas mostradas. En este caso, se modificaron 3 parámetros de entrenamiento, dejándose como estándares los demás. El código utilizado fue el siguiente:

*% Parámetros de entrenamiento*

```
narx_net.trainFcn = 'trainlm'; % Método de entrenamiento LM  
narx_net.trainParam.show = 4; % Núm.épocas mostradas  
narx_net.trainParam.epochs = 50; % Núm.épocas entrenamiento
```

Estos parámetros son flexibles a cambios y modificaciones continuas, debido a que la red se ha probado constantemente, por lo que sólo son referenciales. Para los parámetros como meta o gradiente mínima, se utilizaron los establecidos por defecto. En el caso de la meta de entrenamiento (goal), el valor es 0, mientras que para la gradiente mínima, el valor por establecido es  $10^{-10}$ .

**3.2.7 Entrenamiento de la red neuronal.-** Para el entrenamiento se tuvo que realizar un arreglo adicional, tal que las entradas y salidas, ya no se presentaron como vectores o matrices simples; sino, como estructuras. Las estructuras son matrices más complejas y sirven para que las RNA trabajen más eficientemente.

El código usado es el siguiente:

```
% Adecuamos las entradas para la red Narx
Pc = con2seq(P');
Tc = con2seq(T');

d = 2; % número de delays de la entrada
Pt = [Pc(d+1:end);Tc(d+1:end)];
Tt = Tc(d+1:end);
% Algoritmo para obtener las condiciones iniciales de los delays
for k=1:d,
    Pi{1,k}=Pc{k};
    %Pi{1,k}=0;
end
for k=1:d,
    Pi{2,k}=Tc{k};
end
```

Donde:

Pc: Estructura de patrones de entrada.

Tc: Estructura de targets de salida.

Pt: Estructura de patrones acondicionada para la red Narx.

Tt: Estructura de targets acondicionada para la red Narx.

Pi: Estructura de condiciones iniciales de los delays.

Una vez definida la RNA NARX y acondicionada la data de patrones y targets, el código para el entrenamiento es simple. Se debe tener bastante cuidado en el orden de las matrices y de las estructuras, ya que un error en esta etapa

haría que la red no funcione o tenga un comportamiento bastante inestable. La línea de comando es la siguiente:

```
%% Entrenamiento  
narx_net = train(narx_net,Pt,Tt,Pi);
```

Donde:

narx\_net : Red Neuronal Artificial Narx

Pt: Estructura de patrones de entrenamiento

Tt: Estructura de targets de entrenamiento

Pi: Estructura de patrones y salidas iniciales

**3.2.8 Evaluación de resultados.**- Luego del entrenamiento de la red, se procedió a la revisión de sus resultados para verificar visualmente, su éxito, así como verificar su error, utilizando los criterios correspondientes.

El código utilizado es el siguiente:

```
% Simulación de entrenamiento  
yp = sim(narx_net,Pt,Pi);  
  
y = Ymax*cell2mat(yp);  
  
n = length(y);  
yf = y(1:n);  
Tf = Ymax*cell2mat(Tc(d:n+d-1));  
e = yf - Tf;  
  
ep = e./Tf*100;  
emse = sqrt(mse(ep));
```

Donde:

yp : Estructura normalizada de salida de la RNA con los patrones de entrenamiento.

y : Vector de demanda simulada con los patrones de entrenamiento.

n : Número de muestras de 'y'.

Tf : Vector de demanda real utilizada en el entrenamiento.

e : Vector de error de entrenamiento.

ep : Vector de porcentaje de error por punto.

emse : Error cuadrático medio de entrenamiento.

Una vez validada en entrenamiento la RNA NARX, se procedió a su evaluación en predicción, para tal fin se adquirió, filtro y adecuó los patrones almacenados en el archivo 'prediccion2.txt'.

El código utilizado es el siguiente:

```
%% Definimos patrones futuros de RNA
PTi = load('prediccion2.txt');

val = 1;           % Selección de mes
switch val
case 1
    offset = 0.01;   % factor de incremento de producción
    Pi1 = PTi(:, 1:4);
    Ti1 = PTi(:, 5) + offset;
    set(handles.text23, 'String', 'Agosto 2007');
case 2
    offset = 0.011;  % factor de incremento de producción
    Pi1 = PTi(:, 6:9);
    Ti1 = PTi(:, 10) + offset;
    set(handles.text23, 'String', 'Setiembre 2007');
case 3
    offset = 0.013;  % factor de incremento de producción
    Pi1 = PTi(:, 11:14);
    Ti1 = PTi(:, 15) + offset;
    set(handles.text23, 'String', 'Octubre 2007');
end

% Filtrado de la data
mi = mean(Ti1);    % media de la data
si = std(Ti1);     % desviación estándar
```

```
p = 19;           % periodo de picos (en cuartos de hora)
```

```
% Filtramos de la data futura
```

```
for i = 1:length(Ti1)
```

```
    if Ymax*Ti1(i) < 37000
```

```
        Ti1(i) = 1.05*(mi+0.003*mi*rand(1)) + 0.1*si*rand(1);
```

```
        if (i-floor(i/p)*p) == 0
```

```
            Ti1(i) = 1.005*Ti1(i);
```

```
            Ti1(i-1) = 1.01*Ti1(i);
```

```
            Ti1(i-2) = 1.04*Ti1(i);
```

```
            Ti1(i-3) = 1.04*Ti1(i);
```

```
            Ti1(i-4) = 1.01*Ti1(i);
```

```
            Ti1(i-5) = 1.005*Ti1(i);
```

```
        end
```

```
    end
```

```
end
```

```
Pci = con2seq(Pi1');
```

```
Tci = con2seq(Ti1');
```

```
Pti = [Pci(d+1:end);Tci(d+1:end)];
```

```
Tti = Tci(d+1:end);
```

```
for k=1:d,
```

```
    Pii{1,k}=Pci{k};
```

```
    %Pii{1,k}=0;
```

```
end
```

```
for k=1:d,
```

```
    Pii{2,k}=Tci{k};
```

```
end
```

Donde:

PTi: Patrones futuros para la predicción

val : Selector del mes a predecir

offset : Factor de incremento de la producción

Pti : Estructura de patrones futuros para la predicción.

Pii : Estructura de condiciones iniciales para la predicción.

De acuerdo al algoritmo de entrenamiento de la RNA, establecido en la 'Programación de la RNA', se procedió a establecer los siguientes parámetros de la RNA NARX (número de capas, neuronas por capa, número de delays y funciones de activación).

Tabla 06 - Parámetros a modificar en entrenamiento


Parámetro	Símbolo
Número de neuronas capa 1	S1
Número de neuronas capa 2	S2
Número de delays	D
Función de activación capa 1	FA1
Función de activación capa 2	FA2

Fuente y elaboración propias

El número de épocas se consideró constante e igual a 50, pues el error cuadrático medio se estabiliza entre las épocas 20 y 30. El error podía disminuir si se aumentaba el número de épocas a 100 o 200; sin embargo, se habría producido un sobre-entrenamiento. A continuación se muestran los resultados de los distintos entrenamientos, así como sus respectivos errores:




Figura 34 - Entrenamiento con 2 capas de neuronas, 2 delays y f.a. 'tansig'



S1	S2	d	FA1	FA1	Mse
16	8	2	Tansig	Tansig	0.2769 %

Fuente y elaboración propias (herramienta Matlab)


Figura 35 - Entrenamiento con 1 capa de neuronas, 2 delays y f.a. 'tansig'



S1	S2	d	FA1	FA1	mse
10	0	2	Tansig	-	0.3392 %

Fuente y elaboración propias (herramienta Matlab)


Figura 36 - Entrenamiento con 2 capas de neuronas, 2 delays y f.a. 'tansig'



S1	S2	d	FA1	FA1	mse
10	5	2	Tansig	Tansig	0.3916 %

Fuente y elaboración propias (herramienta Matlab)


Figura 37 - Entrenamiento con 2 capas de neuronas, 4 delays y f.a. 'tansig'



S1	S2	d	FA1	FA1	mse
10	5	4	Tansig	Tansig	0.4535 %

Fuente y elaboración propias (herramienta Matlab)


Figura 38 - Entrenamiento con 2 capas de neuronas, 6 delays y f.a. 'tansig'



S1	S2	d	FA1	FA1	mse
10	5	6	Tansig	Tansig	0.6595 %

Fuente y elaboración propias (herramienta Matlab)


Figura 39 - Entrenamiento con 1 capa de neurona, 6 delays y f.a. 'tansig'



S1	S2	d	FA1	FA1	mse
10	0	6	Logsig	-	0.3915 %

Fuente y elaboración propias (herramienta Matlab)


Figura 40 - Entrenamiento con 1 capa de neurona, 2 delays y f.a. 'logsig'



S1	S2	d	FA1	FA1	mse
10	0	2	Logsig	-	0.3141 %

Fuente y elaboración propias (herramienta Matlab)


Figura 41 - Entrenamiento con 1 capa de neurona, 2 delays y f. a. 'logsig'



S1	S2	d	FA1	FA1	mse
20	0	2	Logsig	-	0.3528 %

Fuente y elaboración propias (herramienta Matlab)


Figura 42 - Entrenamiento con 1 capa de neurona, 2 delays y f.a.'logsig'



S1	S2	d	FA1	FA1	mse
8	0	2	Logsig	-	0.4229 %

Fuente y elaboración propias (herramienta Matlab)

Figura 43 - Entrenamiento con 2 capas de neuronas, 2 delays y f.a.'logsig'



S1	S2	D	FA1	FA1	mse
10	5	2	Logsig	Logsig	0.4399 %

Fuente y elaboración propias (herramienta Matlab)

### 3.3 Operación de la red neuronal:

Una vez acondicionados los patrones futuros de la RNA, se procedió a correr el programa para obtener la data de la demanda eléctrica predicha en el mes seleccionado.

El código utilizado es el siguiente:

```
%% Simulación de predicción
ypi = sim(narx_net,Pti,Pii);

yi = Ymax*(cell2mat(ypi)+offset);

ni = length(yi);
yfi = yi(1:ni);
Tfi = Ymax*cell2mat (Tci (d: ni+d-1));
ei = yfi - Tfi;
tti = 1:ni;

epi = ei./Tfi*100;      % porcentaje de error
emsei = sqrt(mse(epi));
```

Donde:

ypi: Estructura normalizada de salida de la RNA con los patrones de predicción.

yi : Vector de demanda simulada con los patrones de predicción.

ni : Número de muestras de 'y'.

Tfi: Vector de demanda real utilizada en la predicción.

ei : Vector de error de predicción.

epi: Vector de porcentaje de error por punto para la predicción.

emsei : Error cuadrático medio de predicción.

El diseño de la interfaz, se ha basado en los requerimientos específicos de información, así como en la tendencia de predicción necesaria. Los requerimientos de información son:

- Mes de predicción.
- Curva de demanda predicha (período de muestreo cada 15 minutos)
- Energía consumida en el mes.
- Demanda máxima del mes.
- Cargos o pagos diferenciados por consumo y demanda base y adicional.
- Cargos o pagos finales.

En el caso de la predicción, se ha considerado un botón para el entrenamiento de la red neuronal artificial. Este botón, no sólo creará y entrenará la red neuronal artificial, sino que permitirá un nuevo entrenamiento si los resultados no son satisfactorios.

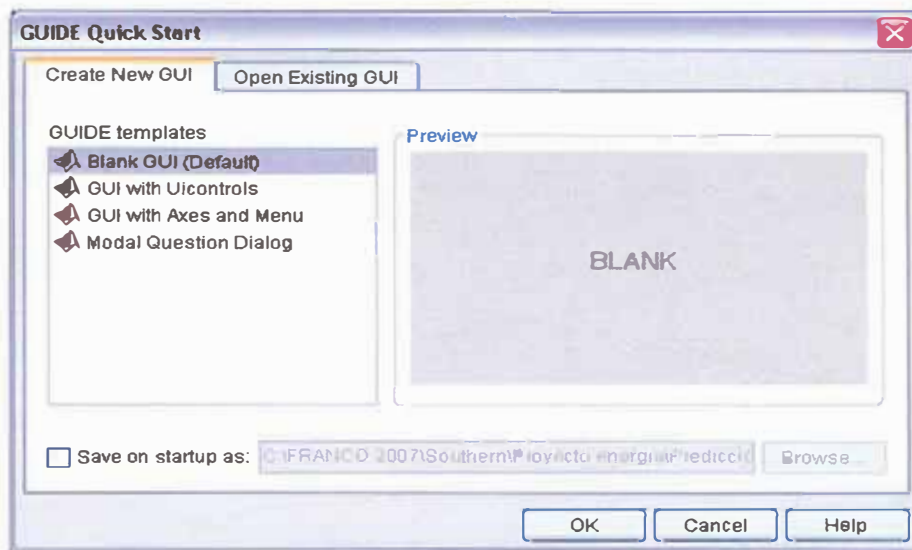
Para el caso de los cargos o pagos a realizar por consumo y demanda, se ha creado la función **pago.m**, basada en la estructura tarifaria. Esta función extrae, una vez obtenida la demanda, los cargos por energía y potencia, base y adicional, desglosados, así como el valor o pago final de la fundición de Ilo, por concepto de consumo y demanda de energía eléctrica.

El error utilizado en el entrenamiento, es el error cuadrático medio (mean square error - MSE):

$$MSE = \frac{\sum_{i=1}^N (y - \hat{y})^2}{N}$$

Para el diseño de la interfaz gráfica, se ha utilizado la herramienta GUIDE de Matlab. Para acceder a esta herramienta, se tipea **'guide'** en el escritorio del software, y se ha seleccionado blank GUI (default), tal como se muestra en la figura 44.

Figura 44 - Ventana inicial de la herramienta GUIDE de Matlab



Fuente: Matlab

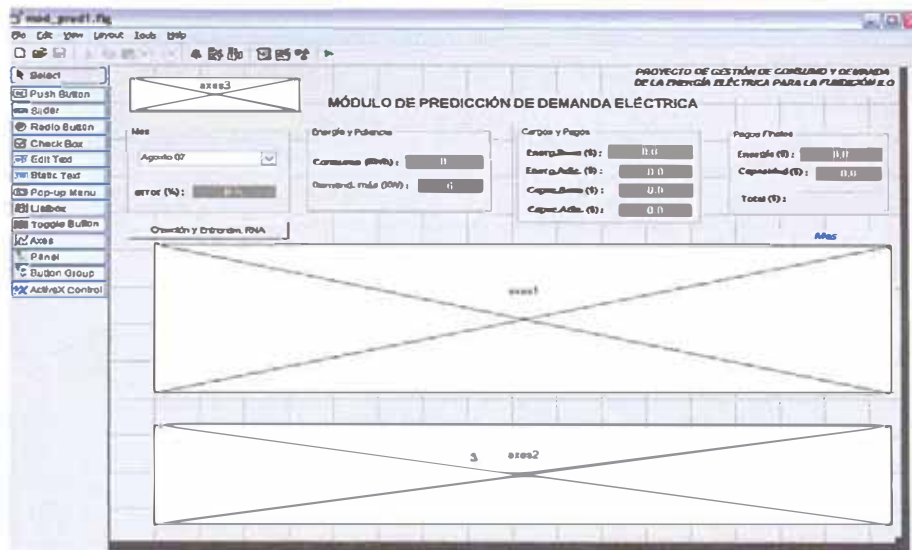
Una vez con la ventana de diseño abierta, se ha elaborado la pantalla de trabajo, colocando y ordenando los objetos necesarios, tal como se muestra en la figura 45.

En el caso del proyecto, se han colocado los siguientes objetos:

- 1 cuadro gráfico (axes1) para la demanda de entrenamiento y predicción.
- 1 cuadro gráfico (axes2) para el error de entrenamiento y predicción.
- 1 botón (push button1) para la creación y entrenamiento de la RNA.
- 1 menú desplegable (pop up menu 1) para la selección del mes a predecir.
- 10 cuadros de texto para los datos relevantes, tales como energía consumida en el mes, demanda máxima y cargos o pagos.



Figura 45 - Pantalla de diseño de la interfaz gráfica

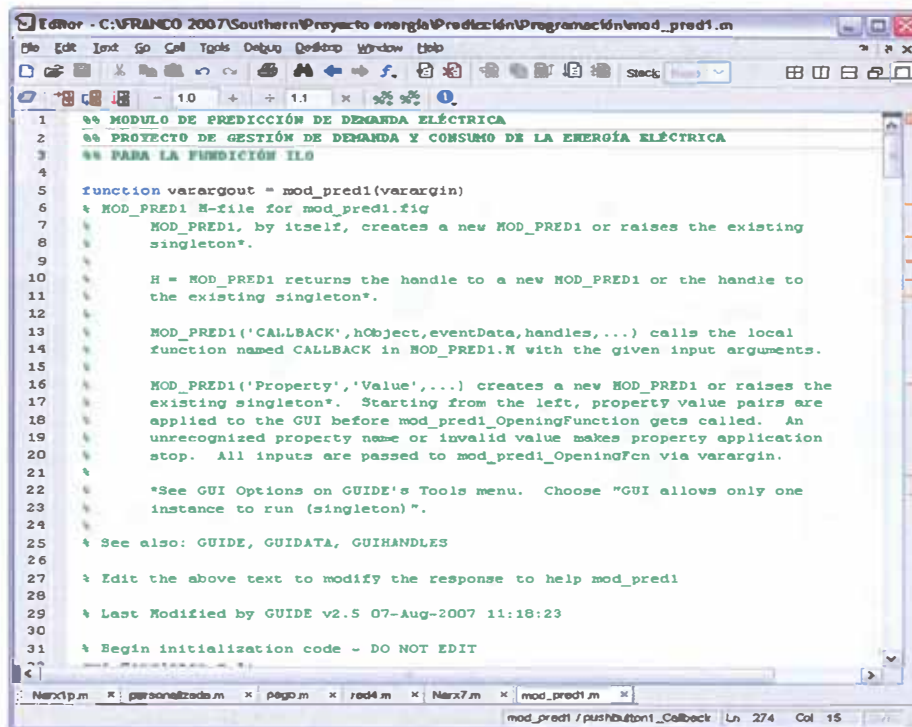


Fuente y elaboración propias (herramienta Matlab)

Una vez diseñada la interfaz gráfica, se han programado los objetos por separado y se ha procedido a realizar los enlaces entre ellos.

En la figura 46, se muestra la pantalla de programación de la interfaz. El código usado trabaja con una programación orientada a objetos, pero con la cualidad de aprovechar al máximo toda la potencia en cálculos matriciales y optimización de memoria de Matlab.

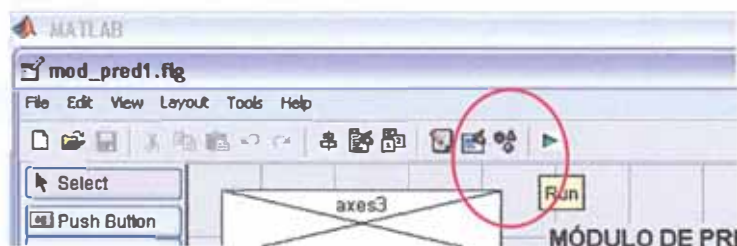
Figura 46 - Pantalla de programación de la interfaz gráfica



Fuente y elaboración propias (herramienta Matlab)

Con la interfaz programada y con los algoritmos de creación, entrenamiento y simulación de la red neuronal añadidos, se procedió a correr, el módulo de predicción, presionando el botón Run, tal como se muestra en la figura 47.

Figura 47 - Pantalla para correr módulo de predicción



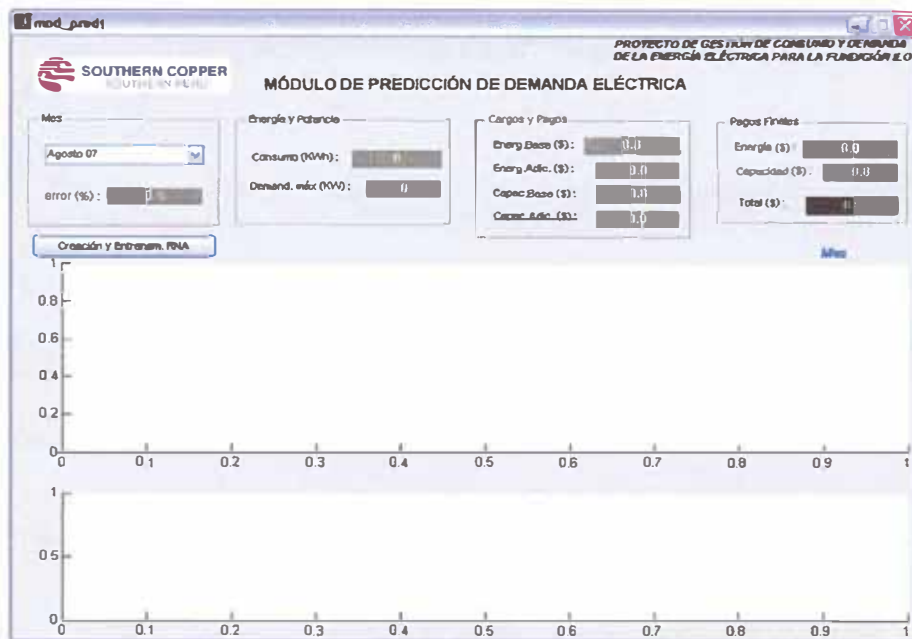
Fuente y elaboración propias (herramienta Matlab)

Otra forma de correr el módulo es escribiendo el nombre del archivo, en el escritorio de Matlab:

>> mod\_pred1

En la figura 48, se muestra la pantalla inicial de trabajo del módulo de predicción de demanda eléctrica:

Figura 48 - Pantalla inicial del módulo de predicción

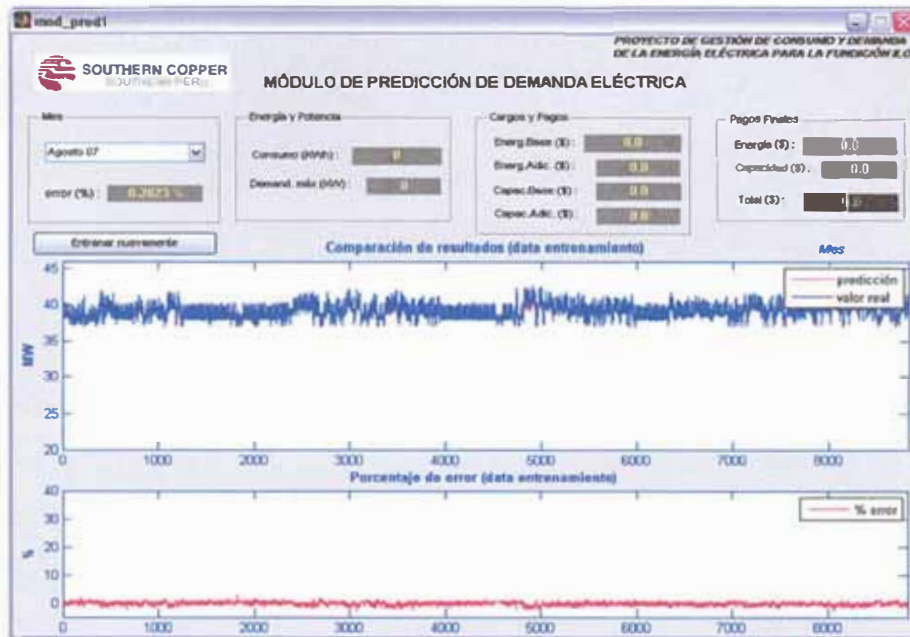


Fuente y elaboración propias (herramienta Matlab)

Una vez con la pantalla de trabajo abierta, como primer paso, se procede a crear y entrenar la RNA NARX. Para esto, se presionará el botón: '**Creación y Entrenam. RNA**'.

Creación y Entrenam. RNA

Figura 49 - Pantalla del modelo luego del entrenamiento




Fuente y elaboración propias (herramienta Matlab)

### 3.4 Prueba del modelo predictivo:

Con la red entrenada y el % error (para entrenamiento) menor a 2%, se procedió a seleccionar un mes del menú desplegable para su predicción y obtención de variables.

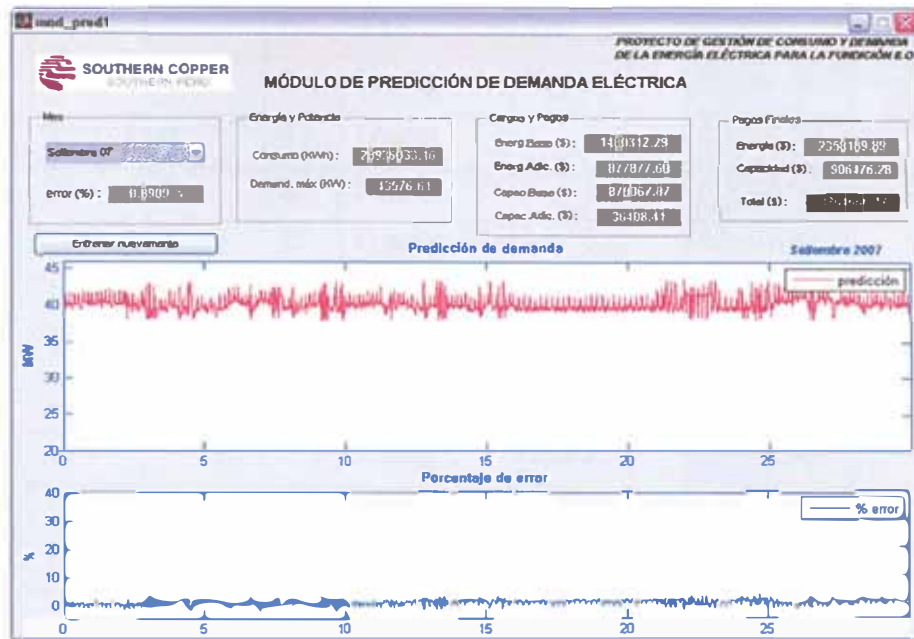
Figura 50 - Menú desplegable



Fuente y elaboración propias

Como ejemplo de resultados, se muestra la demanda predicha para el mes de septiembre del 2007 en la figura 51.

Figura 51 - Pantalla del módulo de predicción



Fuente y elaboración propias (herramienta Matlab)

Como se observa, los valores requeridos, tales como consumo o demanda máxima, se obtienen adecuadamente, siguiendo las tendencias observadas en la data histórica. Los cargos y pagos, a su vez, se basan en el procedimiento de cálculo de la estructura tarifaria' y presentan valores razonables y estables.

A continuación, se muestran los resultados del entrenamiento, para los diferentes parámetros estudiados.

Tabla 07 - Resultados del entrenamiento


S1	S2	D	FA1	FA2	emse
10	5	2	Logsig	Logsig	0.4399 %
8	0	2	Logsig	-	0.4229 %
20	0	2	Logsig	-	0.3528 %
10	0	2	Logsig	-	0.3141 %
10	0	6	Logsig	-	0.3915 %
10	5	6	Tansig	Tansig	0.6595 %
10	5	4	Tansig	Tansig	0.4535 %
10	5	2	Tansig	Tansig	0.3916 %
10	0	2	Tansig	-	0.3392 %
16	8	2	Tansig	Tansig	0.2769 %

Fuente y elaboración propias

Como se observa, en algunos casos al aumentar el valor del parámetro, el error aumenta, a pesar de su alto costo computacional. Sin embargo, para los parámetros elegidos, se observa que se obtiene un mejor desempeño en entrenamiento.

Los parámetros seleccionados, que presentan el menor error cuadrático medio (0.2769%) de las 10 pruebas realizadas, son: 2 capas ocultas de 16 y 8 neuronas respectivamente, 2 delays y funciones de activación 'tansig'. Sin embargo, cabe recalcar que para 1 capa oculta de 10 neuronas, 2 delays y función de activación 'logsig', se obtiene un error de 0.3142%, el cual es muy parecido al error mínimo, pero con mucho menor costo computacional tanto de entrenamiento, y por ende para simulación. Este conjunto de parámetros se tendrá en cuenta como herramienta de respaldo.

Figura 52 - Entrenamiento de la RNA NARX



Fuente y elaboración propias (herramienta Matlab)

La data para la validación es la data formal del servidor IION, que consta en los reportes del departamento de Sistemas de Potencia de Southern Peru.

Para la validación del módulo, se utilizó el error cuadrático medio. El error cuadrático medio en porcentaje se define como:

$$\%e_{rms} = \frac{\sum_{i=1}^N \left( \frac{p_i - r_i}{r_i} \right)^2}{N} \times 100 \quad (1)$$

Donde:

- pi : Dato simulado
- ri : Dato real
- N : Número de muestras

La tabla N° 08 muestra el error cuadrático medio del mes de octubre de 2008; es decir: 0.4862 %, que se ha obtenido mediante la ecuación N° 1

Tabla 08 - Error cuadrático medio

Mes	%erms
Oct-07	0.4862%

Fuente y elaboración propias (herramienta Módulo Predictor)

Se debe tener en cuenta, que durante el mes de octubre del 2007, la producción se mantuvo constante y no hubo caídas o paradas en las plantas, facilitando el cálculo de la demanda futura.

Asimismo, en las tablas N° 09 y N° 10 se presentan el porcentaje de error de la energía y demanda total del módulo de predicción del mes de octubre de 2007, comparándola con la información real.

Tabla 09 - Validación en consumo eléctrico total (total mensual)

Mes	E <sub>predicha</sub> (KWh)	E <sub>real</sub> (KWh)	%error
Oct-07	29,239,640	8,336,177	3.09%

Fuente: Sistema de Potencia de Southern Peru

Elaboración: propia

Tabla 10 - Validación en demanda eléctrica total (máximo mensual)

Mes	D <sub>predicha</sub> (KW)	D <sub>real</sub> (KW)	%error
Oct-07	42,089	42,569	-1.14%

Fuente: Sistema de Potencia de Southern Peru

Elaboración: propia

Para completar la validación de la demanda pronosticada, se presentan los resultados de la energía y demanda eléctrica pronosticada de los meses de noviembre y diciembre de 2007, así como del mes enero de 2008 vs. la información real (ver tabla 11).



Tabla 11 - Comparación de valores pronosticados vs. valores reales

Mes	$E_{\text{predicada}}$ (KWh)	$E_{\text{real}}$ (KWh)	%error	$D_{\text{predicada}}$ (KW)	$D_{\text{real}}$ (KW)	%error
Nov-07	28,892,318	27,310,374	5.48%	43,342	42,356	2.28%
Dec-07	29,796,492	27,803,437	6.69%	42,933	42,492	1.03%
Jan-08	29,795,991	28,342,307	4.88%	42,951	42,330	1.44%

Fuente: Sistema de Potencia de Southern Peru

Elaboración: propia

### 3.5 Modelo de control de demanda:

Para el control de la demanda, el programa requiere que los grupos de cargas (equipos) de cada planta tengan asignados un orden (si será el primero o el último, etc.) y una secuencia de desconexión (FIFO o LIFO), que no genere un pico de demanda.

Estos grupos se crean según la instalación (ejemplo: grupos de compresores o de luces, etc.). Posteriormente a cada grupo se le asignan sus respectivas cargas. Las cargas de cada grupo están ordenadas en función de la máxima demanda contratada. Al mismo tiempo, se establece la secuencia FIFO o LIFO considerando el plan de producción de la planta.

**3.5.1 Método de optimización.**- Para encontrar el conjunto de grupos de equipos que deben operar en la fundición en cada período de tiempo, generalmente una hora, se ha desarrollado un modelo de programación lineal binaria. La variable principal de este modelo es  $x_{ij}$  cuyos valores y características se describen a continuación:

$x_{ij} = 1$ , si el grupo de equipos  $i$  funciona en el horario  $j$ , con  $i = 1, \dots, n$  y  $j = 1, \dots, m$ .

$x_{ij} = 0$ , si el grupo de equipos  $i$  no funciona en el horario  $j$ , con  $i = 1, \dots, n$  y  $j = 1, \dots, m$ .

El modelo evita que se supere la demanda máxima contratada, estableciendo el conjunto de grupos de equipos que pueden operar en los horarios prefijados.

La función objetivo está compuesta por la sumatoria de las cargas  $c_i$ , con  $i=1, \dots, n$ , y la variable  $x_{ij}$  asociada a los grupos de equipos  $i$  que funcionan en el horario  $j$ . Siendo así, la función objetivo se reduce a la siguiente expresión matemática:

Función objetivo es  $Z = \sum_{i=1}^n \sum_{j=1}^m c_i x_{ij}$  que se maximiza.

Sujeto a las siguientes restricciones de operación:

La restricción de demanda máxima contratada:

$0 \leq \sum_{i=1}^n \sum_{j=1}^m c_i x_{ij} \leq d_{\max} - y$ , donde  $y$  es un valor de seguridad para no superar el umbral.

Asimismo, se ha establecido la restricción del presupuesto mensual de electricidad  $b$ , considerando la carga del equipo  $c_i$ , así como la tarifa  $t_j$  (\$/kWh) asociada al horario  $j$ :

$$\sum_{i=1}^n \sum_{j=1}^m c_i t_j x_{ij} \leq b$$

$$x_{ij} \in \{0,1\} \quad i=1, \dots, n \text{ y } j=1, \dots, m$$

Donde:

$$x_{ij} = \begin{cases} 1, & \text{grupo de equipos encendido.} \\ 0, & \text{grupo de equipos apagado.} \end{cases}$$

Este modelo de programación lineal se puede resolver con Matlab. Como ejemplo, se asignaron valores aleatorios a las restricciones del modelo (% Especificaciones:  $n=3$ ,  $m=5$ ,  $d=30$ ,  $ci = [50\ 60\ 30]$ ,  $tj=rand(1, m)$ ,  $dmax=15000$ ,  $y=0.1*dmax$ ,  $b=7000$ ) para encontrar la matriz  $X_{ij}$ .

```
close all; clear all; clc;
```

```
% i: Grupo de equipos => 1 = encendido, 0 = apagado
```

```
% j: Horario => Periodos de 1 hora
```

```
n = 3; % rango i
```

```
m = 5; % rango j
```

```
% Especificaciones
```

```
d = 30; % Unidad: días/mes
```

```
ci = [50 60 30]'; % Unidad: KW
```

```
tj = rand(1,m); % Unidad: $/KW
```

```
dmax = 15000; % Unidad: KW D: Demanda máxima mensual
```

```
y = 0.1*dmax; % Unidad: KW D: Valor de seguridad de la demanda máx.  
mensual
```

```
b = 7000; % Unidad: $/mes D: Presupuesto mensual de electricidad máximo
```

```
% Cálculo de la matriz xij
```

```
% Generando todas las matrices posibles
```

```
p = 2^(n*m);
```

```
g = 1:p;
```

```
for k=1:p
```

```
    xij{k}=dec2bin2(k-1,n*m);
```

```
    xij{k}=reshape(xij{k},n,m);
```

```
end
```

```
% Hallando restricciones
```

```
for k=1:p
```

```
    Z{k} = ci*xij{k};
```

```
    M(k) = sum(Z{k});
```

```
    r1(k) = sum(Z{k})*d - (dmax-y); % Debe ser negativa
```

```
    r2(k) = tj*Z{k}'*d - b; % Debe ser negativa
```

*end*

*% Restricción de demanda máxima mensual (r1)*

*g(find(r1>0))=0;*

*% Restricción de presupuesto mensual de electricidad (r2)*

*g(find(r2>0))=0;*

*% Hallar matriz xij que maximice la función*

*g = find(g>0);*

*[a,pos] = max(M(g));*

*pos = g(pos);*

*Xij = xij{pos}*

*Xij =*

<i>0</i>	<i>0</i>	<i>1</i>	<i>1</i>	<i>1</i>
<i>0</i>	<i>1</i>	<i>1</i>	<i>1</i>	<i>1</i>
<i>0</i>	<i>0</i>	<i>1</i>	<i>0</i>	<i>1</i>

**3.5.2 Método de control.-** Este método se basa en cuatro bloques: el controlador proporcional integral derivativo (PID), el bloque FIFO o LIFO, la planta y el modelo predictivo que realimenta al sistema con el pronóstico de demanda de la planta. Emplea como variables de entrada, el set point o valor deseado de la demanda de energía eléctrica y el valor pronosticado de dicha demanda  $d(t+1)$ , y como variable de salida, la demanda real  $(t)$  que ingresa al módulo predictivo  $d(t)$ .

El controlador compara la demanda pronosticada por el módulo predictivo con el set point de demanda; es decir, la demanda máxima contratada. Esta comparación determina la señal de error del controlador, que puede ser corregida aumentando o reduciendo los grupos de equipos en funcionamiento, de acuerdo al arreglo de la matriz  $X_{ij}$ , que se obtiene mediante el modelo de programación lineal de la planta.

El valor devuelto por el controlador (valor continuo) indica la cantidad de grupos que deben estar en marcha. Considerando que el controlador PID determina la cantidad de carga en un valor continuo y que la carga total al hacer funcionar ciertos grupos va a ser descrita al tomar una combinación de estos (esto es, tomando valores referenciales como demanda máxima de cada grupo), la respuesta del controlador debe traducirse a valores discretos para activar o desactivar un grupo de equipos.

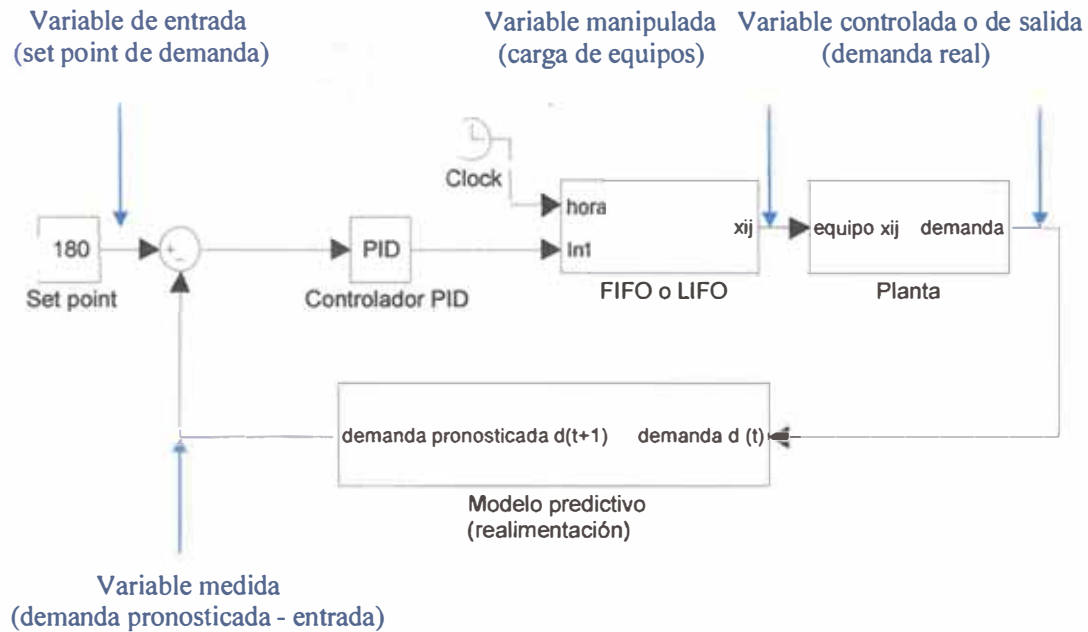
El bloque FIFO o LIFO lo que hace es primero determinar qué hora es; segundo, determinar qué grupos de equipos deben estar activados en esa hora que no hayan sido desactivados manualmente; tercero, generar una “pila” con el orden de activación o desactivación (ya sea FIFO o LIFO) de estos grupos; y cuarto, tomar la respuesta del controlador y compararlo con la pila (siempre siendo la carga escogida inmediatamente inferior al valor entregado por el controlador para no pasar del rango seguro) con el objetivo de realizar la activación.

La planta está formada por los grupos de equipos ordenados en FIFO o LIFO que define el orden de activación y desactivación, pues todos los equipos no funcionan a cada hora. La tabla (matriz  $X_{ij}$ ) indica que grupos de equipos deben funcionar o se pueden desactivar manualmente, por ello se ha agregado un reloj que determine, junto con la matriz  $X_{ij}$ , los grupo de equipos que se desactivarán a cierta hora.

El modelo predictivo permite, a través de las demandas históricas y las actuales, que se leen cada 15 minutos, predecir la demanda de energía eléctrica del siguiente período también de 15 minutos, cuyo valor es comparado con el set point de esta misma variable(valor deseado).

En la figura 53, se presenta el diagrama de bloques del control propuesto.

Figura 53 - Diagrama de control

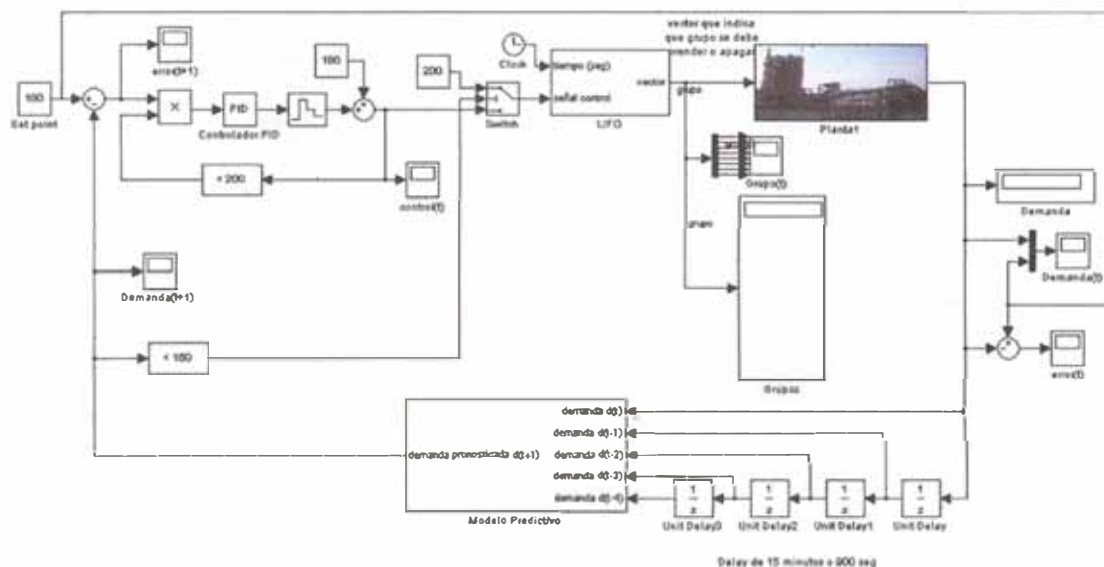


Fuente y elaboración: propia

**3.5.3 Simulación del programa de control.-** Se ha desarrollado la simulación para evaluar el comportamiento del sistema real. Ésta se basa en el método de control descrito en el apartado anterior. Las variables de entrada consideradas son el set point de la demanda de energía eléctrica igual a 180 MW y el valor pronosticado de dicha demanda  $d(t+1)$ , calculado por el modelo predictivo para los 15 minutos siguientes al período  $d(t)$ . Esta variable de salida realimenta a la la red NARX del módulo predictivo.

El programa de control de demanda se ha simulado en Matlab para evaluar el comportamiento del sistema real, según se aprecia en la figura 54.

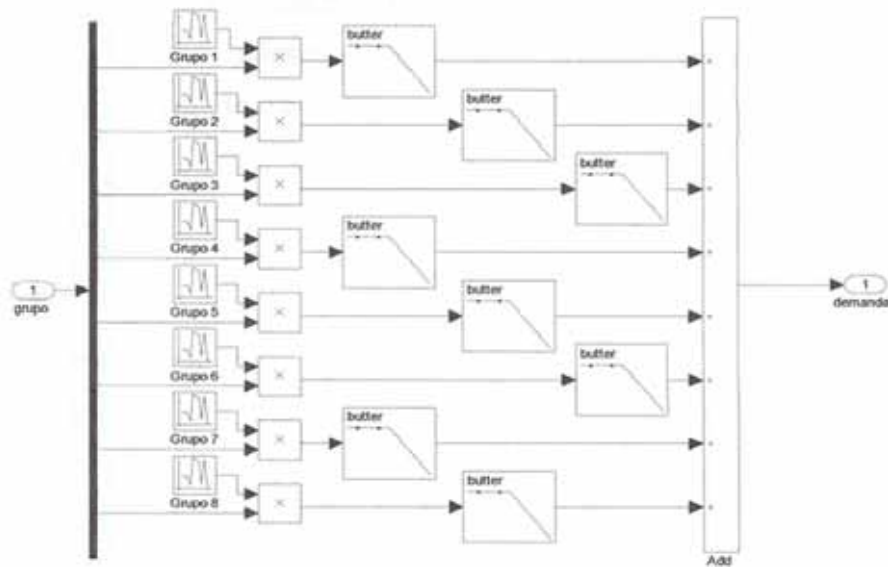
Figura 54 - Pantalla de simulación



Fuente y elaboración: propia

En la planta, se consideraron 8 grupos de equipos en 24 horas que generan un número aleatorio con distribución gaussiana y media igual al valor esperado de la demanda; luego se usó un filtro para simular un proceso continuo. Para la activación o desactivación de cada grupo se aplicó en la entrada 0 ó 1 respectivamente (figura 55).

Figura 55 - Esquema de la planta



Fuente y elaboración: propia

El modelo predictivo está conformado por una red neuronal NARX, que predice la demanda de la planta en base a la tendencia que ésta presenta. El siguiente bloque es el controlador PID que corrige la demanda activando o desactivando a cada grupo (ver figura 56); sin embargo, para cerrar el lazo se transformó el valor del controlador que es continuo respecto al de la planta que es binario. Es así que se creó el último bloque, LIFO, que hace esta comunicación y que además permite hacer un calendario de funcionamiento de cada equipo por horas. Con este calendario, se puede hacer que el grupo  $i$  esté desactivado a la hora  $j$  independientemente del control.

El grupo LIFO tiene por entradas al tiempo y la señal del controlador. El tiempo está dado en horas en un rango entero de 1 a 24. La señal del controlador permite seleccionar en el calendario (bloque con matriz  $X_{ij}$ ), que equipo puede entrar en funcionamiento en el período siguiente para no superar el umbral de demanda deseado.

La matriz  $X_{ij}$  es obtenida mediante el modelo de programación lineal, que representa el conjunto óptimo formado por las variables  $x_{ij}$  asociadas a grupo de equipos  $i$  en el horario  $j$ , y se calcula después de haberlos agrupados





ser la demanda. Luego, el bloque LIFO transforma este valor en un vector que indica cuales grupos deben seguir encendidos.

En sí, el controlador sólo debe corregir la demanda cuando ésta sobrepase el valor de 180MW, en caso contrario básicamente, lo que se hace es desactivar al controlador; sin embargo al desactivar al controlador, se generan dos problemas:


El primero es que no podemos desactivar al controlador cada vez que la demanda pronosticada sea menor que 180 MW, pues al ser el set point de 180 MW, se estaría disminuyendo su rendimiento porque cada vez por efecto de la amortiguación, el controlador esté debajo de este nivel sería desactivado. Por esta razón, la desactivación se hace con un valor de 160 MW.

El segundo problema es la saturación del integrador del controlador. Cuando la demanda es menor, no se toma en cuenta la señal de control, pero el controlador sigue leyendo el error, y considerando que no es nulo, el componente integrativo sigue cargándose.

Esto no sería ningún problema ya que cuando el error sea negativo, el integrador se descarga, pero la acción de control sería más lenta pues hay que esperar primero a que se descargue el integrador. Para evitar esto se ha colocado un bloque que cada vez que la señal de control empiece a saturarse (tome valores por encima de los 200MW), vuelve nulo al error evitando este efecto.

A continuación, se presenta la pantalla donde aparecerán los grupos de equipos adecuados.

Figura 57 - Modelo de simulación




Fuente y elaboración: propia

En la simulación se pudo encontrar el siguiente arreglo de grupos de equipos:  
100, 35, 25, 10, 5, 10, 5, 5.

Este arreglo se visualiza gráficamente en la figura 58.

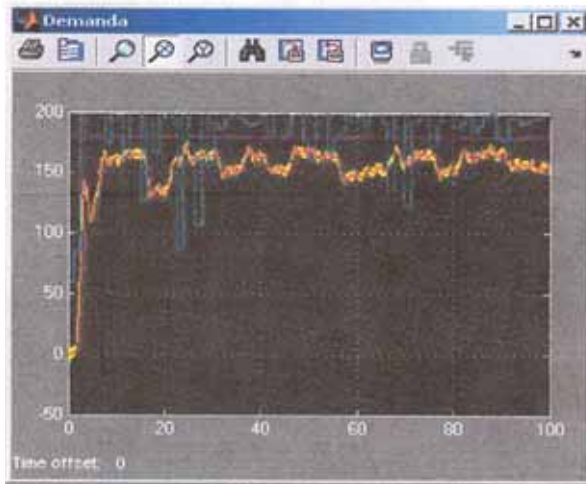
Figura 58 - Modelo de simulación



Fuente y elaboración: propia

El programa de control mantiene la demanda por debajo de los 180 MW, con los grupos de equipos adecuados, data se aprecia en el anexo data simulada (figura 59).

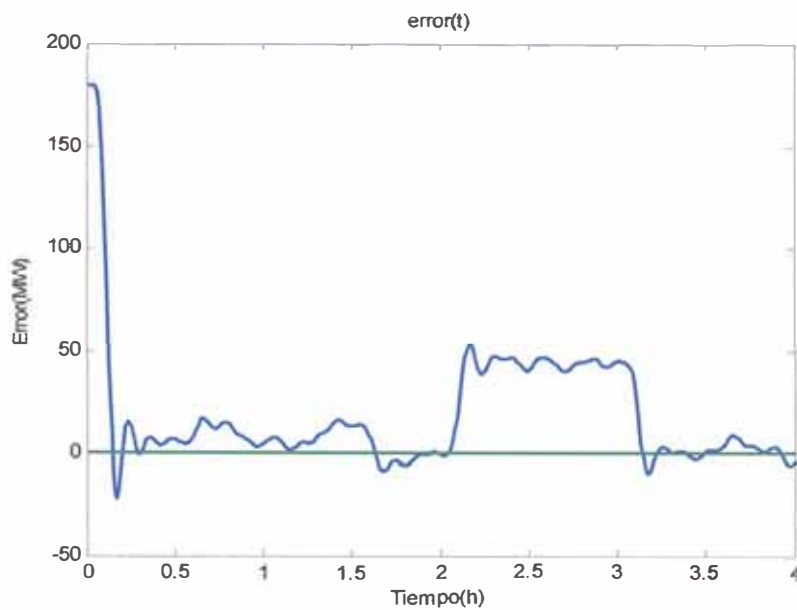
Figura 59 - Modelo de simulación



Fuente y elaboración: propia

Línea celeste: demanda sin programa de control. Línea amarilla: demanda con control. Línea rosada oscura: set point de demanda

Figura 60 - Error (demanda de planta vs. valor deseado 180MW)




Fuente y elaboración: propia

Cuando la demanda pronosticada es menor a 180MW, el controlador sale de funcionamiento permitiendo a todos los grupos de equipos, que debe funcionar

en un determinado horario, estar activados. Este hecho se observa en la cresta mostrada en el error entre la segunda y tercera hora; durante el cual ningún grupo es prendido o apagado (ver figura 61).

Figura 61 - Control del funcionamiento de grupos de equipos



Fuente y elaboración: propia

Cuando se pronostica que la demanda va a ser mayor a 180MW, el controlador funciona desactivando en un orden LIFO cada grupo hasta que la demanda pronosticada sea menor.

**3.5.4 Implementación del programa de control.-** Los grupos de equipos se pueden conectar al control de demanda, según el diagrama mostrado en la figura 62.

Figura 62 - Diseño de instalación



Fuente: Programa de control de demanda

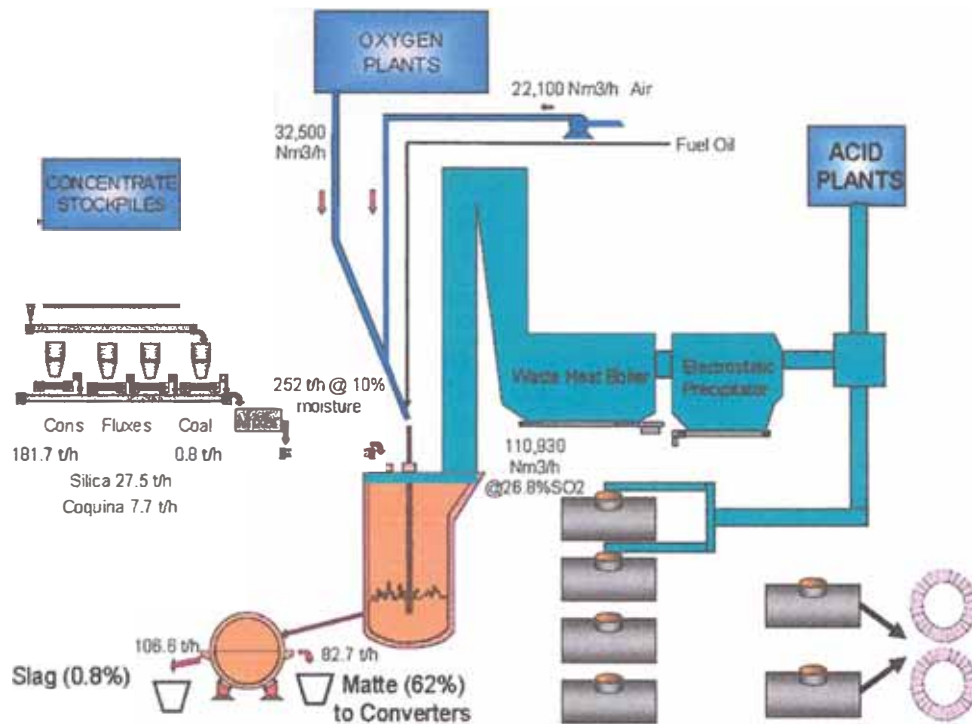
### **3.6 Caso de aplicación:**

Para evaluar el comportamiento de la demanda, aplicando el programa de control propuesto, se ha usado el modelo de simulación de la Planta de Ácido 2(PAS2) de la fundición de Ilo, que el autor ha desarrollado para el sistema de gestión de demanda y consumo de energía eléctrica de dicho complejo metalúrgico.

En esta simulación, se presentan 02 escenarios: el primero, sin el programa de control de demanda y el segundo, aplicando dicho programa a la planta de ácido. Para ello, se han diseñado selectores que ponen fuera de operación los equipos del área de limpieza, así como los del área de contacto y ácido débil, para evitar que se supere el umbral de demanda máxima. Los resultados se detallan en el anexo 05 de la tesis.

La Planta de Ácido 2 produce mensualmente un promedio de 67,000 TM de ácido sulfúrico. El ácido sulfúrico es obtenido al procesar los gases resultantes de la fusión de concentrados del horno Isasmelt, que ingresan a través del Waste Heat Boiler y el Electrostatic Precipitator, según se aprecia en la figura 63.

Figura 63 - Diagrama de flujo de la Planta de Ácido 2



**Fuente:** Reporte de producción Planta de ácido

**Elaboración:** Propia

Se ha modelado el sistema de control en cascada de los sopladores. Este sistema regula la apertura de las válvulas IGV (Inlet Guide Vanes) para permitir el flujo de los gases calientes del proceso de fusión.

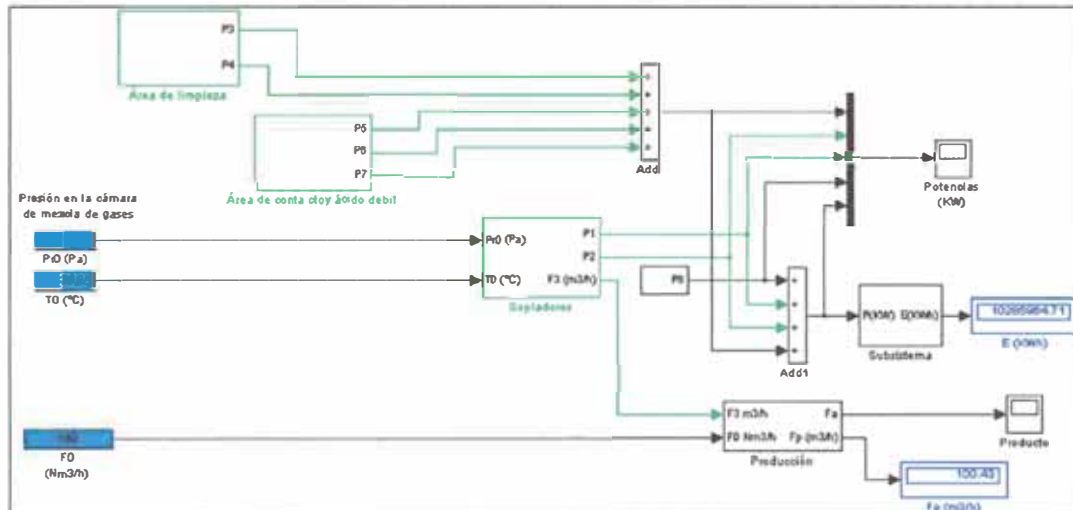
El controlador de presión PIC410001, ubicado en el ducto de ingreso de gases a la Planta de Ácido 2, genera una señal de control Pr0\_out (0-100%) en función de la presión Pr0 con la que ingresan a la planta. Ésta señal llega al controlador de corriente que regula el porcentaje de apertura de las válvulas IGV: H1 y H2 de los sopladores.

En la figura 64, se observa la pantalla principal del modelo de simulación de la Planta de Ácido 2. Las variables de entrada son la presión de ingreso (Pr0), la temperatura de ingreso (T0) y el flujo de ingreso (F0) de los gases



provenientes del proceso de fusión de concentrado en la fundición. La salida principal es el ácido sulfúrico así como la demanda o lectura de potencias.

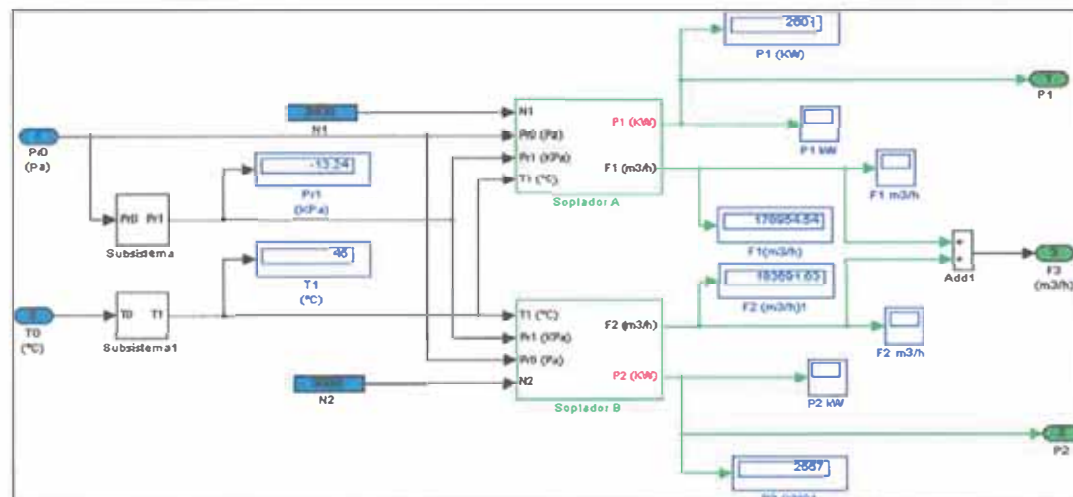
Figura 64 - Modelo de simulación de la Planta de Ácido 2



Fuente: Gerencia de fundición de Southern Peru  
 Elaboración: Propia

En la figura 65, se observa la pantalla de simulación de los sopladores A y B, cuyas salidas son los flujos de gases de cada equipo.

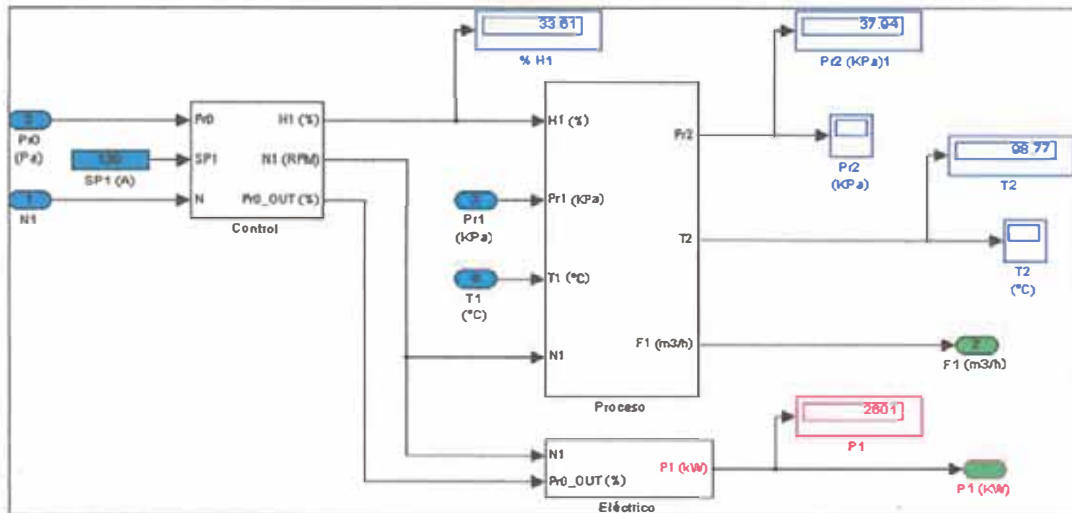
Figura 65 - Diagrama de bloques de los sopladores A y B



Fuente: Gerencia de fundición de Southern Peru  
 Elaboración: Propia

En la figura 66, se presenta la pantalla de soplador A (similar al B), teniendo como salidas los flujo de gases, así como la potencia demandada por dicho soplador.

Figura 66 - Pantalla del soplador A (7510C-A)

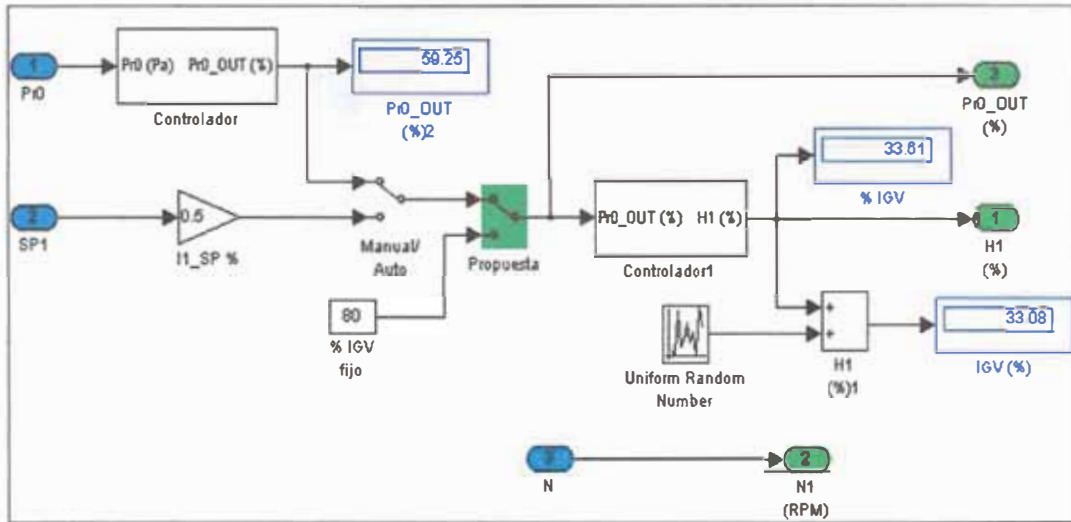


**Fuente:** Gerencia de fundición de Southern Peru

**Elaboración:** Propia

En la figura 67, se muestra la pantalla del subsistema de control del soplador A. La regulación del flujo de gases, que pasa por el soplador, depende del porcentaje de abertura de la válvula IGV. Cuando se presenta un aumento de presión en la entrada, entonces el porcentaje de abertura de la válvula IGV aumenta.

Figura 67 - Pantalla del subsistema de control

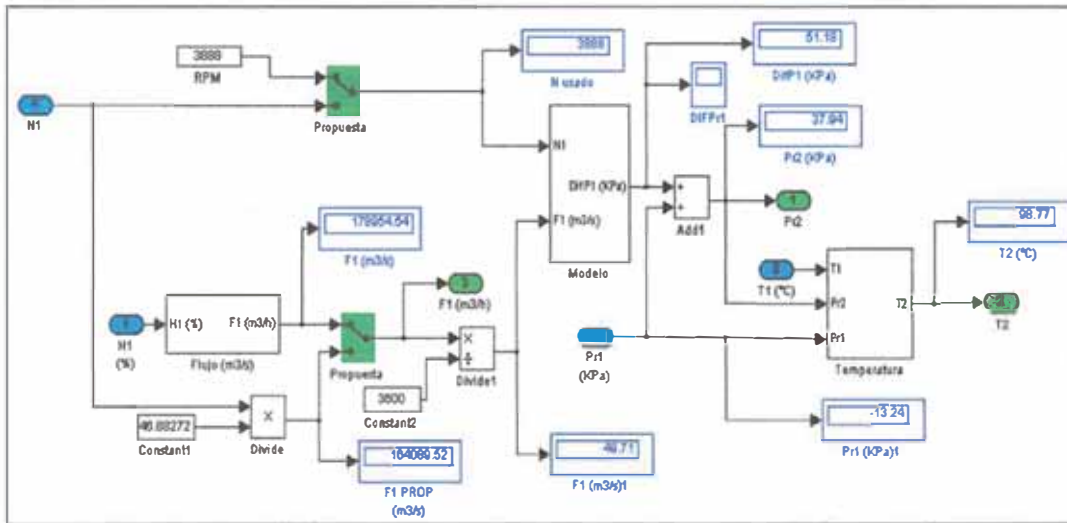


**Fuente:** Gerencia de fundición de Southern Peru

**Elaboración:** Propia

En la figura 68, se presenta la pantalla del subsistema de proceso. Los datos de entrada son la velocidad del giro del soplador, el porcentaje de abertura de la válvula IGV, la presión y la temperatura en el ducto de ingreso al soplador. Luego del cálculo del flujo de gas, se aplica la relación cúbica de Moore y Greitzer para hallar el aumento de presión. Después se calcula la temperatura y la presión de salida.

Figura 68 - Pantalla del subsistema de proceso

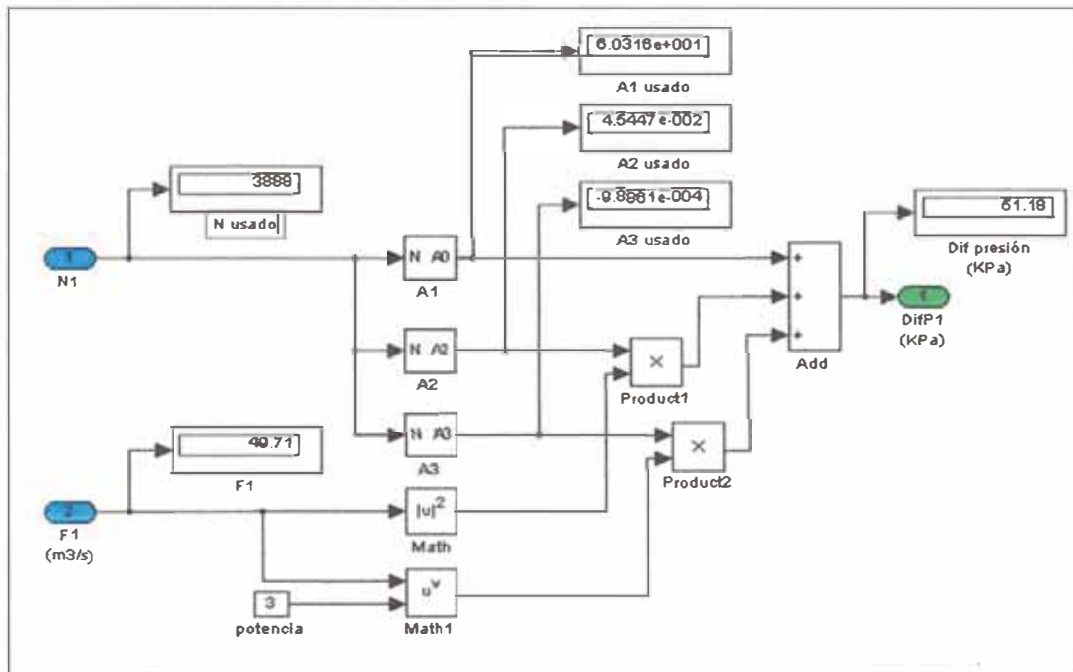


**Fuente:** Gerencia de fundición de Southern Peru

**Elaboración:** Propia

En la figura 69, se aprecia la relación de Moore y Greitzer usada para calcular el aumento de presión en el soplador. A más revoluciones por minuto, la presión de descarga de gases será mayor.

Figura 69 - Pantalla del modelamiento del soplador

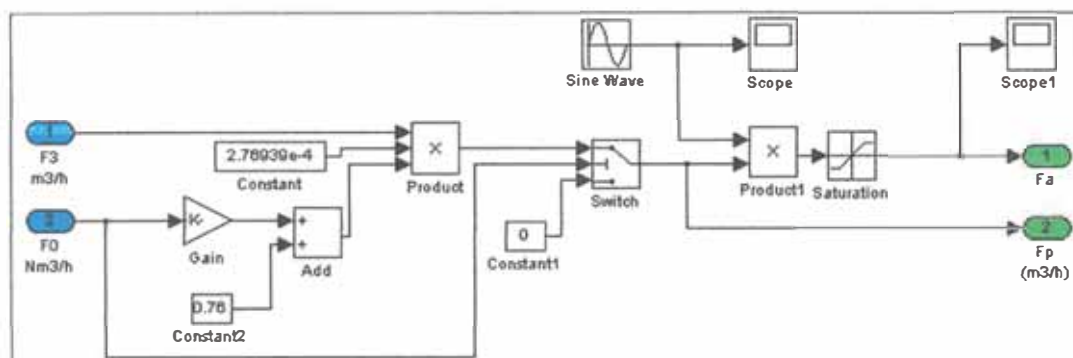


Fuente: Gerencia de fundición de Southern Peru

Elaboración: Propia

En la figura 70, se muestra la pantalla del cálculo de la producción de ácido de la planta. Las variables de entrada con el flujo de gases impulsado por los sopladores y el total de gases calientes que recibe la PAS2.

Figura 70 - Pantalla del cálculo de la producción



Fuente: Gerencia de fundición de Southern Peru

Elaboración: Propia

Los principales parámetros del proceso que están relacionados con los sopladores A (7510C-A) y B (7510C-B) en la Planta de Ácido 2 son los siguientes:

- Control de flujo por Inlet Guide Vane (IGV)
- Diferencia de presión: 48-57 kPa
- Flujo promedio: 151,000-193,000 m<sup>3</sup>/h de gases
- Diferencia de temperatura: 50-60 °C
- Potencia promedio: 2300-2800 KW
- Velocidad de giro de los sopladores: 3888 RPM

El objetivo es que la diferencia de presión se mantenga constante y dentro del rango especificado para la succión y evacuación de los gases dentro del circuito de la planta.

El escenario de funcionamiento actual de la planta considera como variable controlada a la corriente de cada soplador en función de la presión de los gases en el ducto de ingreso a la Planta de Ácido 2.

Condiciones iniciales:

- Presión en el ducto de ingreso a la PAS2: 600 Pa
- Temperatura del los gases calientes: 238°C
- Flujo de gases calientes: 180 Nm<sup>3</sup>/h
- Velocidad de giro de los sopladores: 3888 RPM

Se realizó la simulación del modelo de la PAS2 con los datos de operación actuales.

### 3.6.1 Resultados de la Simulación:

- Demanda media del soplador A es 2653 Kw.
- Demanda media del soplador B es 2613 Kw.
- El flujo de salida promedio del soplador A es 180,617 m3/h.
- El flujo de salida promedio del soplador B es 185,031 m3/h.
- La demanda media de la Planta de Ácido 2 es 7229 Kw.

Se generó el intervalo de confianza de una muestra aleatoria de la demanda real, obtenida por medio del Active Factory, la data que se obtuvo fue del día 20 de agosto del 2007 de 8:00 AM a 3:00 PM, la demanda fue registrada cada 5 minutos. Se utilizó un nivel de confianza del 99%.

Tabla 12 - Datos de simulación

Media	7,246.104
Desviación estándar	73.6181
Nivel de confianza	99%
Z	2.576
Valor máximo	7392.5754
Valor mínimo	7113.5671

Fuente y elaboración propia

El valor media de la demanda obtenida en el simulador es de 7,246.104 Kw. Se puede notar que el valor obtenido pertenece al intervalo de confianza (7,228.79 < 7,263.42) por lo que se puede afirmar que la demanda obtenida del proceso de simulación tiene un 99% de confianza. Asimismo tiene un error cuadrático de 0.02% con respecto a la demanda real de la Planta de Ácido 2.


El error cuadrático se calcula con la siguiente fórmula:

$$\%e_{rms} = \frac{\sum_{i=1}^N \left( \frac{p_i - r_i}{r_i} \right)^2}{N} \times 100$$

Donde:

pi: Dato simulado  
ri: Dato real  
N: Número de muestras

Figura 71 - Demanda real vs. simulada (Planta de Ácido 2)



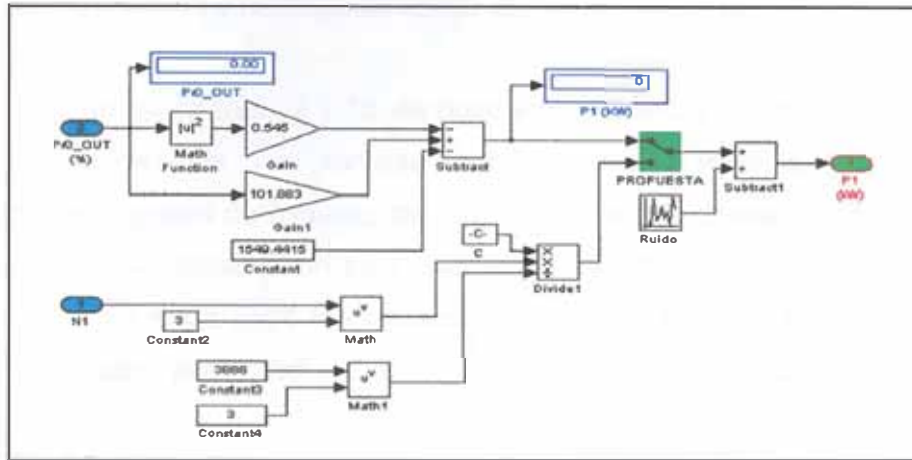
**Fuente:** Gerencia de fundición de Southern Peru

**Elaboración:** Propia

En la figura 72, se muestra la pantalla del subsistema eléctrico. La potencia consumida por el soplador depende de la señal del controlador de presión del gas en el ingreso a la planta (Pr0\_out). El selector resaltado con color verde permite simular el escenario con el control de demanda para sacar de operación a los equipos, que - sin afectar el proceso productivo - disminuyen la demanda de energía eléctrica y por ende su consumo.



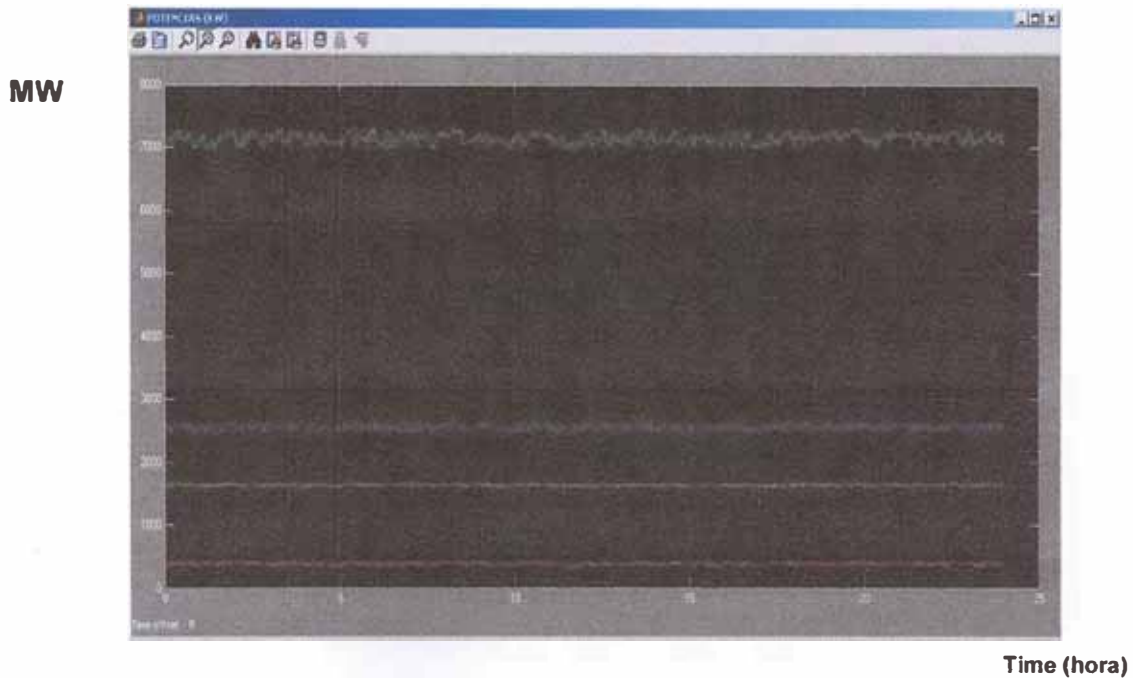
Figura 72 - Pantalla del subsistema eléctrico



Fuente: Gerencia de fundición de Southern Peru  
 Elaboración: Propia

El proceso productivo de la Planta de Ácido 2 tiene una demanda superior a los 7000 Kw sin el programa de control de demanda, según se aprecia en la figura 73.

Figura 73 - Demanda de Planta de Ácido



Fuente: Gerencia de fundición de Southern Peru

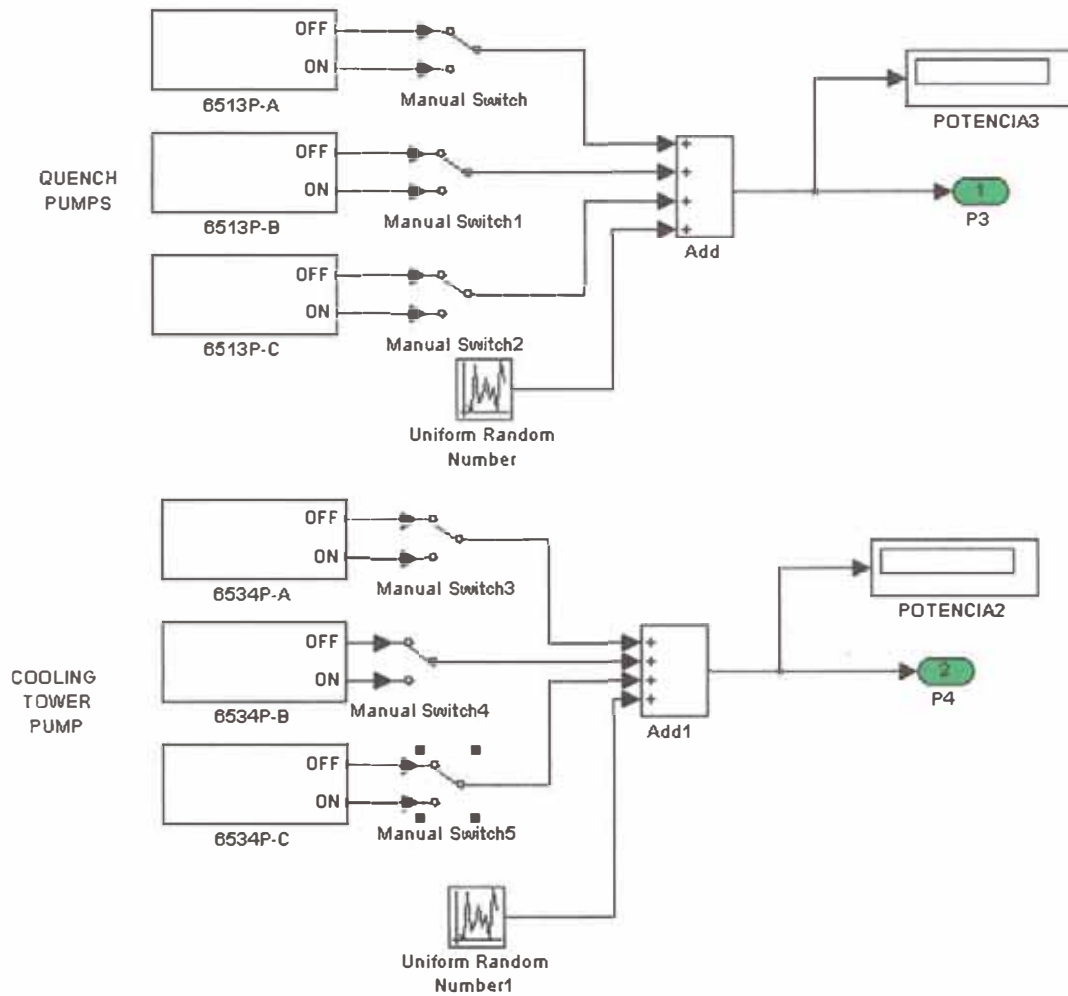
Línea verde: demanda de 100% de equipos funcionando

Líneas roja, amarilla y celeste: demanda de plantas y contacto débil.

Asimismo, en las figuras 74 y 75, se pueden apreciar los selectores (resaltados con color verde) que - al ponerse en off - limitan el funcionamiento de los equipos de la planta de limpieza así como del área de contacto y ácido débil, permitiendo una disminución de la demanda de energía eléctrica de toda la planta de 7200 Kw a 5500 Kw en promedio. Esta reducción implica un menor consumo de energía de toda la planta, según el detalle mostrado en el anexo 5 (Data Simulada.xls).

De esta misma forma, actúa el programa de control de demanda para evitar los picos no deseados en el período de tiempo monitoreado. Los valores de funcionamiento con el programa de control de demanda desactivado y en operación se aprecian en anexo 4.

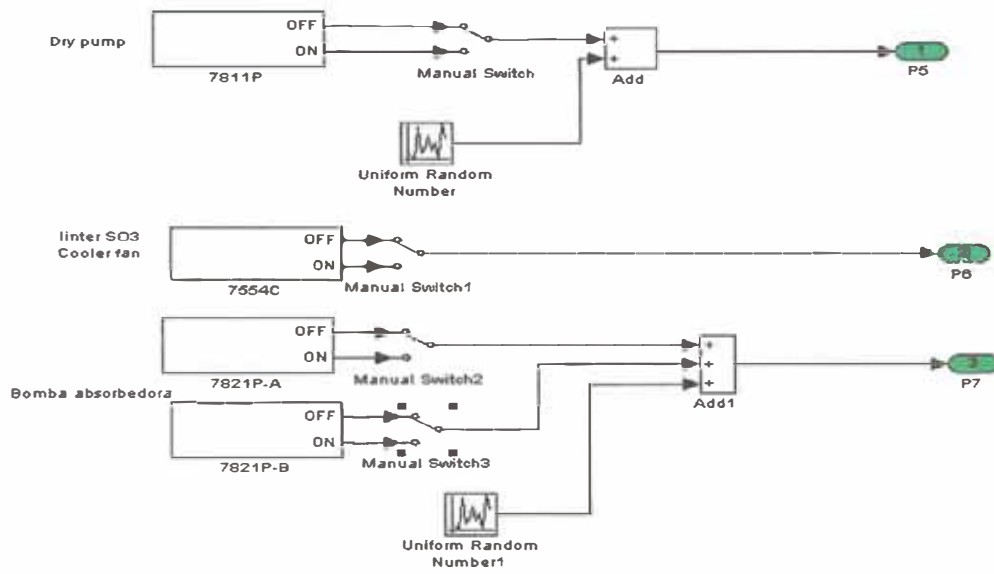
Figura 74 - Diagrama eléctrico de planta de limpieza



Fuente: Gerencia de fundición de Southern Peru

Elaboración: Propia


Figura 75 - Diagrama eléctrico de área de contacto y ácido débil



Fuente: Gerencia de fundición de Southern Peru

Elaboración: Propia

Figura 76 - Curva de la demanda con el control de demanda



MW

Time (hora)

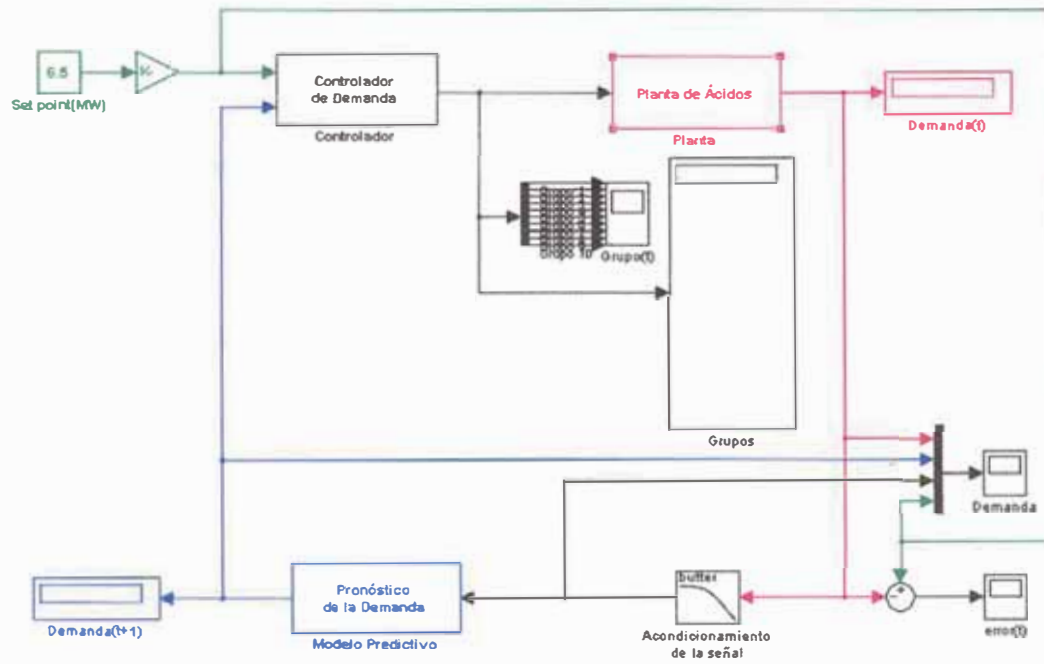
Fuente: Gerencia de fundición de Southern Peru

Línea verde: demanda de 100% de equipos funcionando

Líneas roja, amarilla y celeste: demanda de plantas y contacto débil

El programa de control de demanda opera en la Planta de Ácido, siguiendo el esquema mostrado en la figura 77.

Figura 77 - Programa de control de demanda en Planta de Ácido



Fuente: Fundición de Ilo  
Elaboración propia

## CAPÍTULO IV

### CONCLUSIONES Y RECOMENDACIONES

#### ***4.1 Conclusiones respecto de los objetivos del modelo predictivo:***

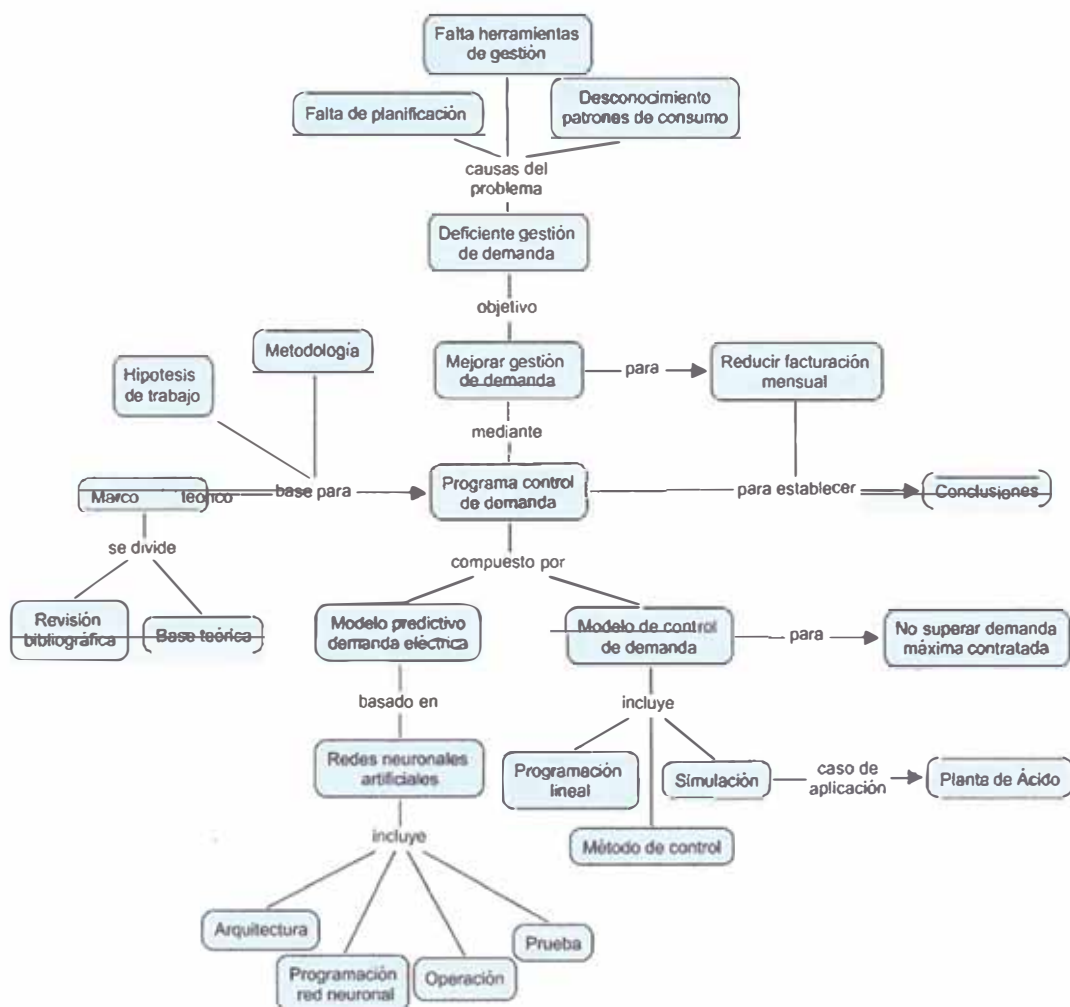
- El tipo de red neuronal Narx dinámica modificada, se comporta adecuadamente para el modelo predictivo, según se pudo apreciar en las pruebas efectuadas en el apartado 4.4.
- Los patrones calendarios resultan apropiados para el modelo predictivo, según se ha podido determinar en la presente investigación; asimismo, es necesario considerar patrones de producción y la demanda del mes anterior para un modelamiento adecuado de la red neuronal, conforme es de verse del apartado 4.1.1.
- La red NARX dinámica permitió pronosticar la demanda eléctrica horaria con un error porcentual de 2,28%, 1,03% y 1,44% en los meses de agosto a octubre de 2007, conforme se aprecia en el apartado 4.4.
- Las redes neuronales son una herramienta muy potente para el pronóstico de la demanda de electricidad, conforme se aprecia en el apartado 4.4.
- El pronóstico de la demanda futura facilita la planificación de la demanda de energía eléctrica, pues – como se aprecia en el apartado 4.5.1 – su valor pronosticado se compara con el valor deseado, estableciéndose una estrategia de control para los períodos críticos.

#### **4.2 Conclusiones respecto de los objetivos del modelo de control de demanda:**

- El programa de control de demanda desarrollado permite mejorar la gestión de la demanda, al evitar que se produzcan demandas no deseadas; asimismo, permitirá reducir el consumo de las plantas, conforme se aprecia del apartado 4.5
- La estrategia de control recomendable está basada en un modelo predictivo, con ventanas deslizantes.
- El método matemático adecuado para ordenar la secuencia de operación de los grupos de equipos es el modelo de programación lineal binaria, según el procedimiento de optimización descrito en el apartado 4.5.1.
- Se ha establecido con claridad que el control de demanda evita la formación de picos no deseados, conforme es de verse de la simulación del programa de control de demanda y su caso de aplicación.

Para recapitular y resumir el desarrollo de la investigación, se presenta el mapa mental de la tesis en la figura 78, que muestra inicialmente las causas de la deficiente gestión de demanda de energía eléctrica. Esta situación constituye el problema central de la investigación, y establece el objetivo de mejorarla para reducir la facturación mensual, mediante un programa de control de demanda compuesto por un módulo predictivo de demanda eléctrica y un módulo de control de demanda. El primero está basado en redes neuronales artificiales y el segundo en un controlador proporcional integral derivativo. El marco teórico de esta investigación incluyó la revisión de bibliografía especializada y la teoría de redes neuronales y controladores. Asimismo, como parte de la investigación, se simuló en Matlab el programa de control de demanda y se pudo validar su utilidad en la Planta de Ácido de Southern Peru, cuya simulación forma parte de esta tesis.

Figura 78 - Estructura de la tesis



Fuente y elaboración propias

### 4.3 Recomendaciones:

- Es conveniente diseñar modelos de gestión de demanda basados que se ejecuten mediante el programa de control de demanda.
- Es recomendable evaluar más detenidamente los patrones climáticos.
- Se debe evaluar la posibilidad de masificar el uso de controladores de demanda en la industria.
- Es conveniente establecer indicadores de performance para los controladores de demanda.



## BIBLIOGRAFÍA

[01] Turabian, Kate. Manual for Writers of research, papers, theses and dissertations, Chicago style for students and researchers. University of Chicago Press Editorial Staff, 7<sup>th</sup> edition, 2007.

[02] Canzio, Luis. Construyendo una Planta de Control Digital, Southern Peru Copper Corporation, 2006.

[03] Aristizabal Restrepo, María. Evaluación asimétrica de una red neuronal artificial: Aplicación al caso de la inflación en Colombia Trabajo realizado para optar el título de Economista en la Universidad Eafit. 2006.

[04] Simon G., Lendasse A., Cottrell M., Fort J.-C., Verleysen M.. Time series forecasting: Obtaining long term trends with self-organizing maps. Machine Learning Group-DICE-Université Catholique de Louvain, Belgium. Helsinki University of Technology-Laboratory of Computer and Information Science, Neural Networks Research Centre. Université Paris I-Panthéon Sorbonne, France. Université Paul Sabatier Toulouse 3, France. 2005.

[05] Sanchez, Edgar; Alamis, Alma. Predicción de la demanda eléctrica usando redes neuronales, entrenadas por filtro de Kalman. Universidad Michoacana de San Nicolás de Hidalgo, Morelia, Michoacan, México. Junio 2004.

[06] Venero Castro, Antony. A neural network approach to predict hurricane intensity in the north Atlantic basin. Tesis (Grado: Master of Science in Industrial Engineering), Puerto Rico. University of Puerto Rico.2004

[07] Kapsoli Salinas, Javier y Benich Aguilar, Brigitt, Indicadores líderes, redes neuronales y predicción de corto plazo. Trabajo de investigación. Pontificia Universidad Católica del Perú. 2002.

[08] Radgen Peter, Technik der Rationellen Energienutzung Teil 1, Modul Energietechnik / Rationelle Energienutzung, Universität Koblenz, 2002.

[09] Perez Ortiz, Juan Antonio. Modelos predictivos basados en redes neuronales recurrentes de tiempo discreto. Tesis (Grado: Doctor en Ciencias), Alicante, España. Departamento de Lenguajes y Sistemas Informáticos de la Universidad de Alicante. 2002.

[10] Mallo Carlos, Predicción de la Demanda Eléctrica Horaria mediante Redes Neuronales Artificiales. Departamento de Economía Cuantitativa. Universidad de Oviedo, 2002.

[11] Meisenbach and R. Lux. Lastprognose konventionell oder mit neuronalen Netzen - ein Vergleich. In Optimierung in der Energieversorgung: Planungsaufgaben in liberalisierten Energiemärkten, pages 207–217. VDI-Verlag, Düsseldorf, 1999.

[12] Gareta, Raquel; Romeo Luis M.; Gil, Antonia y Monzón, Alberto. Las redes neuronales como herramienta para predecir el precio de la energía eléctrica. Centro de Investigación de Recursos y Consumos Energéticos (CIRCE). Universidad de Zaragoza. Centro Politécnico Superior. María de Luna. Zaragoza. 1999.

[13] Petridis and A. Kehagias. Predictive Modular Neural Networks, applications to time series, Kluwer, 1998.

[14] Hufendiek Kai. Einsatz künstlicher neuronaler Netze beider kurzfristigen lastprognose. Institut für Energiewirtschaft und Rationelle Energieanwendung, 1997.

- [15] Bakirtzis, A. J. Theocharis, S. Kiartzis and K Satsios, "Short Term Load Forecasting Using Fuzzy Neural Networks", paper 95 WM 155-2- PWRS presented in IEEE/PES 1995, Winter Meeting.
- [16] C. N. Lu, H. T. Wu And S. Vemuri, Neural Network Based Short Term Load Forecasting, IEEE Trans. On Power Systems, Vol. 8, N° 1, pp. 336-342, 1993.
- [17] Ho L. Hsu Y. and C. C. Yang, "Short Tern Load forecasting using a multilayer Neural Network with an Adaptive Learning Algorithm" IEEE Trans. On power systems, Vol. 7, N° 1, pp. 141-149, 1992
- [18] CIGRE Working group. WG 39.03: Present practices on load forecasting and load management: A survey. In Electra, N° 145, Paris, pp. 69-89, December, 1992.
- [19] Gross G. and F. D. Galiana. "Short term load forecasting, "Proc. IEEE, Vol 75, N° 12 p. 1558-1573, 1987.
- [20] Schneider Electric, Control de demanda. Disponible en << <http://www.schneider-electric.com.mx>.
- [21] ENth Energy, Sustanaible Energy Management. Disponible en << <http://www.entheenergy.com/Energy/DemandControl/tabid/106/Default.aspx>>>.
- [22] Braun, J. S. Klein, W. Beckman, and J. Mitchell. 1989a. "Methodologies for optimal control of chilled water systems without storage," ASHRAE Transactions. 652-662.
- [23] Braun, J. S. Klein, J. Mitchell, and W. Beckman. 1989b. "Applications of optimal control to chilled water systems without storage," ASHRAE Transactions. 663-675.

## GLOSARIO DE TÉRMINOS

**Carga.**- Potencia activa o aparente consumida o suministrada a una máquina o a una red. Cantidad de energía eléctrica entregada o requerida en cualquier punto o puntos de un sistema.

**Carga contratada.**- Magnitud de carga solicitada por el abonado al sistema de generación eléctrica.

**Carga máxima.**- Máximo valor de la demanda o también la máxima carga que se presenta durante un período determinado (diaria, semanal, mensual o anual).

**Consumo.**- El consumo de energía facturado es aquel efectivamente medido durante el período de medición, por lo general un mes. La unidad de medición del consumo es el kW-h.

**Curva de carga.**- Representación gráfica de la variación observada o esperada de carga en función al tiempo.

**Curva de la demanda.**- Es un registro de la demanda en un período de tiempo dado, por lo general 1 día.

**Demanda.**- Es la potencia o carga promedio que se obtiene durante un intervalo de tiempo especificado (intervalo de demanda). En nuestro país, este período es de 15 minutos. La unidad de medición de la demanda es el kW.

**Demanda base.**- Es la mínima carga demandada del sistema de generación eléctrica en un período de tiempo.

**Energía activa.**- Energía eléctrica transformable en otra forma de energía.

**Equipo de suministro eléctrico.**- Equipo que alimenta, modifica, regula, controla o protege un suministro eléctrico.

**Estación de generación.**- Una planta donde se produce energía eléctrica por conversión de alguna otra forma de energía (por ejemplo, química, nuclear, solar, mecánica o hidráulica) por medio de aparatos apropiados. Esto incluye

todos los equipos auxiliares de la planta de generación y otros equipos asociados necesarios para la operación de la planta. No se incluyen las estaciones que producen potencia para uso exclusivo de sistemas de comunicaciones.

**Factor de demanda.-** Relación de la demanda máxima y la carga conectada en un punto del sistema eléctrico.

**Factor de potencia.-** Relación entre potencia activa y la potencia aparente. Para una máquina es también, el cociente de la resistencia y la impedancia de la misma.

**Factor de utilización.-** Relación de demanda máxima y la capacidad instalada de un sistema.

**Período de integración de la potencia.-** Intervalo de tiempo de una hora (media hora) (cuarto de hora), durante el cual se mide el consumo para determinar la potencia media horaria (semi-horaria) (cuarto de hora).

**Potencia.-** Magnitud de un suministro de energía eléctrica, expresada en kilowatt o kilovolt ampere.

**Potencia firme.-** Es la potencia que puede suministrar cada unidad generadora con alta seguridad de acuerdo a lo que defina el Reglamento.

**Potencia instalada.-** Suma de potencias nominales de los receptores de energía eléctrica conectada a la red.

**Potencia máxima solicitada.-** Valor límite solicitada por el cliente.

**Sistema interconectado.-** Conjunto de líneas de transmisión y subestaciones eléctricas conectadas entre sí, así como sus respectivos centros de despacho de carga, que permite la transferencia de energía eléctrica entre dos o más sistemas de generación.

**Sistema principal de transmisión.-** Es la parte del sistema de transmisión, común al conjunto de generadores de un Sistema Interconectado, que permite el intercambio de electricidad y la libre comercialización de la energía eléctrica.

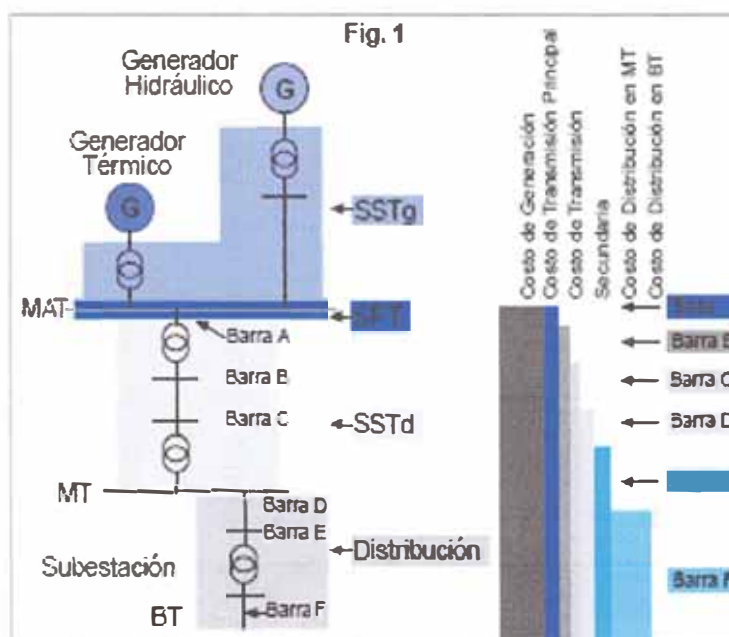
**Suministro.-** Entrega, provisión. Por extensión aplícase a la acometida.

**Tarifa.-** Especificaciones que definen los elementos considerados y los métodos a emplearse para el cálculo de los montos que serán pagados al suministrador por el consumo, de conformidad con las características del suministro.

**Tarifa de exceso de potencia.**- Tarifa en la cual se produce un aumento en los precios cuando la potencia utilizada por el cliente supera un límite fijado en el acuerdo.

**Watt.**- La unidad eléctrica de potencia. Un kW equivale a 1000 vatios.

Figura 79 - Esquema distribución energía eléctrica



- SPT: Sistema Principal de Transmisión
- SST: Sistema Secundario de Transmisión
- VAD: Valor agregado de Distribución
- MAT: Media Alta Tensión
- AT: Alta Tensión
- MT: Media Tensión
- BT: Baja Tensión

# ANEXOS

Tabla 13 - Cuadro de elección de tema de tesis

Maestría	Área de investigación	Tema	Tema específico	Especificación del tema	Problema preliminar	Hipótesis	Variables
Ingeniería de sistemas	Inteligencia artificial	Redes neuronales	Modelo predictivo de demanda de energía eléctrica	Aplicación de redes neuronales a un modelo 'predictivo de demanda de energía eléctrica horaria de una planta industrial	¿Cómo mejorar la actual gestión de demanda de energía eléctrica en las empresas industriales y reducir la facturación mensual por este concepto, mediante un programa de control de demanda, que integre un modelo predictivo basado en redes neuronales artificiales, con la arquitectura (entradas, capas, número de neuronas y salidas) funciones de activación y patrones de entrada, que minimicen el error de pronóstico por debajo del 3 % , así como un modelo de control de demanda con los parámetros y métodos matemáticos adecuados.	Si se desarrolla un programa de control de demanda, que integre un modelo predictivo basado en redes neuronales artificiales, así como un modelo de control de demanda con los parámetros y métodos matemáticos adecuados, se mejorará la actual gestión de demanda de las empresas industriales y se reducirá la facturación mensual por este concepto.	VI: <ul style="list-style-type: none"> <li>▪ Programa de control de demanda</li> <li>▪ Modelo predictivo</li> <li>▪ Modelo de control de demanda</li> </ul> VD: <ul style="list-style-type: none"> <li>▪ Gestión de demanda</li> <li>▪ Facturación eléctrica</li> </ul>

Fuente y elaboración propias

Tabla 14 - Cuadro diagnóstico para el planteamiento del problema

1. Síntomas	2. Causas	3. Pronóstico	4. Control al pronóstico
<p>1. Sobre costos de energía eléctrica</p> <p>2. Altos montos de facturación por consumo de energía eléctrica</p>	<p>1. Desconocimiento de patrones de consumo.</p> <p>2. Deficiente gestión de la demanda de energía eléctrica.</p> <p>3. Falta de planificación.</p> <p>4. Limitaciones de métodos de proyección tradicionales.</p>	<p>1. Los sobre costos de energía eléctrica le harán perder competitividad en el mercado.</p> <p>2. Se desaprovecharán ingentes recursos económicos por dichas ineficiencias, con su consiguiente perjuicio económico.</p>	<p>Es necesario mejorar la gestión demanda de energía eléctrica de la fundición de Southern Peru, que produzca ahorros a la empresa, sobre la base de un modelo predictivo de demanda horaria, basado en redes neuronales, para facilitar la implementación de un programa de gestión de demanda de energía eléctrica.</p>

Fuente y elaboración propias



Tabla 15 - Inventario de equipos

UNIVERSIDAD NACIONAL DE INGENIERÍA POSTGRADO MAESTRÍA INGENIERÍA SISTEMAS		Proyecto :	Tesis de Maestría		
Inventario de Equipos					
n°	Proceso	Sub Proceso	Medidor	Equipo (s)	MEDIDAS
1	Plantas de Oxígeno	Plantas de oxígeno 2 Gral.	1113	Alimentación Principal	12400Kw
			11000	Linea de llegada a la barra	12400Kw
			11002	Main air compressor D111B	5750Kw
			11003	Main air compressor D111A 8045HP	5500Kw
		11001	Transformer MIF-1 P11 2500kVA 13.8/4.16kV	840Kw	
		11004	Transformer 2500kVA 13.8/0.48kV	230Kw	
		1204	AREA 70 Planta de oxígeno 1 Gral.	3500Kw	
1208	Planta de oxígeno 1 Gral.	314Kw			
2	Plantas de Ácido	Planta de ácido 2 Gral.	12002	Alimentación Principal	6900Kw
			12000	Linea de llegada a la barra	6900Kw
			12001	BLOWER MAIN DRIVE #1	2290Kw
			12002	BLOWER MAIN DRIVE #2	2239Kw
		12003	TRANSFORMER 5000KVA 13.8/4.16kV	1600Kw	
		12004	TRANSFORMER 2500KVA 13.8/0.48kV	420Kw	
		1209	Planta de ácido sulfúrico N°1	28Kw	
1205	Planta de ácido 1 Gral.	2600Kw			
1208	Planta de ácido 1 Gral.	314Kw			
1209	Planta de ácido 1 Gral.	28Kw			
3	Convertidores y Hornos de Limpie.	Soplador de Convertidor Gral.	1093	BLOWER #6	1875Kw
			1094	BLOWER #5	1875Kw
			1092	BLOWER #7	1875Kw
			1042	BLOWER #1 Convertidor 4	1725Kw
			1043	BLOWER #2	1725Kw
		1229	Soplador de convertidor Gral.	3Kw	
		1514	290-MCC-001	394Kw	
		1095	Operación de conver. Gral.	148Kw	
		1231	Oper. De Conver. Gral.	26Kw	
		1096	Barra LC-101 480V Converter Area	126Kw	
4	Manejo de Gases y Polvos	Precipitador de Convertidor 2	1233	Precipitador de conv. 2	80Kw
			1231	Precip. Conv.2	44Kw
		Precipitador del ISA Gral.	1559	310-PXF-001	280Kw
			1558	310-ESP-001	245Kw
			1535	310-FAN-001	175Kw
		Precipitador CPS Gral.	1517	321-MCC-001	77Kw
			1516	320-ESP-002	65Kw
			1515	320-ESP-001	60Kw
Manejo de Gases CPS	1514	290-MCC-001	59Kw		
	1561	320-MCS-002 - Transformer 320-VFD-002/ 320-	250Kw		
	1560	320-MCS-001 - Transformer 320-VFD-001/ 320-	250Kw		
	1514	290-MCC-001	320Kw		
1517	321-MCC-001	88Kw			
5	Toma de Agua de Mar	Toma de agua de mar	1527	620-PMP-002	874Kw
			1528	620-PMP-003	857Kw
			1522	620-PMP-001	430Kw
			1530	Load center 620-MCC-002	216Kw
			1534	620-MCC-001	80Kw
6	Horno ISASMELT y Hornos RHF	Horno de Fusión ISA Gral.	1202	00931-US-A	674Kw
			1550	Area 612	465Kw
			1554	220-MCC-002	124Kw
			1555	220-MCC-001	121Kw
			1229	Horno de fusión isa gral.	7Kw
		1209	Horno de fusión isa gral.	28Kw	
		Soplador de ISA Gral.	1562	270-BLO-001	1275Kw
Horno Sep. Meta-escoria Gral.	1557	230-MCC-002	68Kw		
1553	230-MCC-001	60Kw			
7	Distribución Aire Comprimido	Serv. Gral. Sistema de aire comprimido	1095	Centac (DCS KWH) 600HP	486Kw
			1230	DCS-KWh Comp. EPE300#1	246Kw
			1245	630-ACO-001	245Kw
			1228	DCS-KWH Comp. EPE300 # 4	92Kw
			1232	DCS-KWH Comp. EPE300 # 2	0Kw
8	Planta Desalinizadora y Potabilizac	Planta desalinizadora Gral.	1521	640-ACO-002	439Kw
			1520	640-ACO-001	435Kw
			1529	640-PDP-001	168Kw
9	Planta de Ánodos	Planta de ánodos Gral.	1544	295-MCC-001	15Kw
			1549	295-MCC-002	94Kw
		Moldeo General	1233	Moldeo General	370Kw
1231	Moldeo Gral.	87Kw			
10	Varios	Gerencia de Mantenimiento	1231	Ger. Mtto.	18Kw
			1237	Transformer 4.16/0.48kV Slag Haulers//Mantena	106Kw
			1040	Ilum. Pública & Edif. Públicos	22Kw
11	Preparación de Minerales	Manejo de Concentrados Gral.	1039	130-MCC-002	187Kw
			1040	Manejo de Concentrados Gral.	22Kw
			1545	130-MCC-001	93Kw
12	Preparación de Fundentes	Chancadora de Fundentes	1542	140-CRU-001 400HP	132Kw
			1546	140-MCC-002	84Kw
			1040	Chancadora de fundentes	66Kw
			1214	Chancadora secundaria cónica de fundentas	42Kw
			1209	Chancadora de fundentes	28Kw
13	Planta de Cal	Planta de cal	1238	MCC111	203Kw
14	Planta de Efluentes	Planta de Tratamiento de Efluentes 2	1565	Transformer 460-XFR-001 4.16/0.48kV	88Kw
			1533	690-MCC-001	0Kw

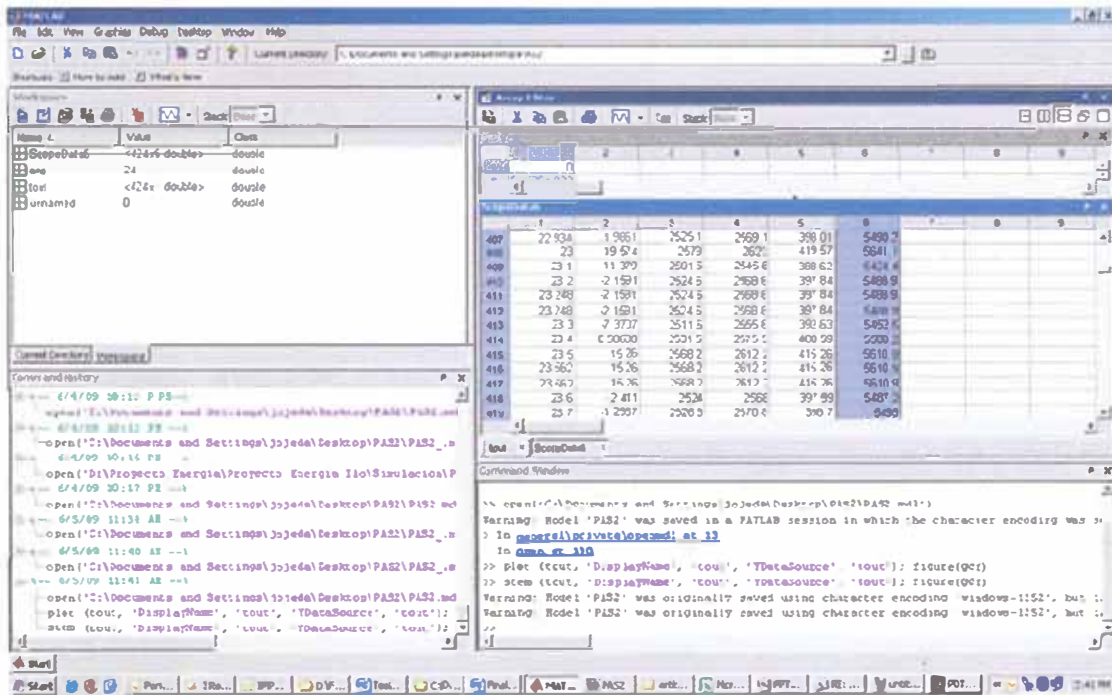
Tabla 16 - Demanda real vs. demanda simulada

DATA		
Tiempo	Demanda Real (KW)	Demanda Simulada (KW)
20 Aug 2007 08:00:00:000	7,180.6299	7,288.9994
20 Aug 2007 08:05:00:000	7,224.9399	7,318.8701
20 Aug 2007 08:10:00:000	7,196.7402	7,318.8701
20 Aug 2007 08:15:00:000	7,357.8701	7,315.8426
20 Aug 2007 08:20:00:000	7,155.0698	7,392.5754
20 Aug 2007 08:25:00:000	7,271.4399	7,361.5274
20 Aug 2007 08:30:00:000	7,114.8198	7,178.0218
20 Aug 2007 08:35:00:000	7,130.2002	7,178.0218
20 Aug 2007 08:40:00:000	7,284.2002	7,198.4973
20 Aug 2007 08:45:00:000	7,236.2300	7,211.0115
20 Aug 2007 08:50:00:000	7,397.3501	7,256.4439
20 Aug 2007 08:55:00:000	7,272.5498	7,278.2390
20 Aug 2007 09:00:00:000	7,256.0601	7,349.6021
20 Aug 2007 09:05:00:000	7,195.8599	7,228.1098
20 Aug 2007 09:10:00:000	7,167.6401	7,348.3502
20 Aug 2007 09:15:00:000	7,199.3198	7,188.1361
20 Aug 2007 09:20:00:000	7,176.0298	7,229.0377
20 Aug 2007 09:25:00:000	7,295.0200	7,229.0377
20 Aug 2007 09:30:00:000	7,217.9102	7,263.1723
20 Aug 2007 09:35:00:000	7,220.2798	7,243.7441
20 Aug 2007 09:40:00:000	7,246.9399	7,193.1467
20 Aug 2007 09:45:00:000	7,150.8301	7,193.1467
20 Aug 2007 09:50:00:000	7,170.1401	7,162.6590
20 Aug 2007 09:55:00:000	7,128.6899	7,155.7688
20 Aug 2007 10:00:00:000	7,126.2900	7,272.7906
20 Aug 2007 10:05:00:000	7,184.0298	7,337.4008
20 Aug 2007 10:10:00:000	7,251.5098	7,121.9823
20 Aug 2007 10:15:00:000	7,352.7300	7,262.3732
20 Aug 2007 10:20:00:000	7,256.4800	7,262.3732
20 Aug 2007 10:25:00:000	7,181.9399	7,252.3017
20 Aug 2007 10:30:00:000	7,191.4800	7,380.2282
20 Aug 2007 10:35:00:000	7,120.2202	7,322.2492
20 Aug 2007 10:40:00:000	7,273.7500	7,322.2492
20 Aug 2007 10:45:00:000	7,209.7798	7,268.0107
20 Aug 2007 10:50:00:000	7,373.3799	7,362.1337
20 Aug 2007 10:55:00:000	7,246.3599	7,287.6850
20 Aug 2007 11:00:00:000	7,358.7598	7,348.4983
20 Aug 2007 11:05:00:000	7,282.0298	7,157.4621
20 Aug 2007 11:10:00:000	7,375.3301	7,172.2976
20 Aug 2007 11:15:00:000	7,174.2402	7,312.8460
20 Aug 2007 11:20:00:000	7,198.6499	7,312.8460
20 Aug 2007 11:25:00:000	7,219.0298	7,149.2469
20 Aug 2007 11:30:00:000	7,283.8198	7,138.2045
20 Aug 2007 11:35:00:000	7,153.8599	7,189.6119
20 Aug 2007 11:40:00:000	7,146.2998	7,189.6119
20 Aug 2007 11:45:00:000	7,189.3701	7,113.5671
20 Aug 2007 11:50:00:000	7,164.7002	7,228.7293
20 Aug 2007 11:55:00:000	7,152.6802	7,120.2526
20 Aug 2007 12:00:00:000	7,131.0601	7,311.4767

DATA		
Tempo	Demanda Real (KW)	Demanda Simulada (KW)
20 Aug 2007 12:05:00:000	7,188.6602	7,375.3385
20 Aug 2007 12:10:00:000	7,150.2900	7,179.9022
20 Aug 2007 12:15:00:000	7,147.9600	7,179.9022
20 Aug 2007 12:20:00:000	7,278.0298	7,163.3781
20 Aug 2007 12:25:00:000	7,359.2700	7,201.6383
20 Aug 2007 12:30:00:000	7,224.3101	7,361.0846
20 Aug 2007 12:35:00:000	7,325.9902	7,361.0846
20 Aug 2007 12:40:00:000	7,245.8901	7,154.8210
20 Aug 2007 12:45:00:000	7,272.8501	7,303.5042
20 Aug 2007 12:50:00:000	7,322.4322	7,303.5042
20 Aug 2007 12:55:00:000	7,253.2444	7,220.7553
20 Aug 2007 13:00:00:000	7,298.6542	7,221.2903
20 Aug 2007 13:05:00:000	7,223.7854	7,252.6547
20 Aug 2007 13:10:00:000	7,320.4563	7,252.6547
20 Aug 2007 13:15:00:000	7,210.9702	7,154.0365
20 Aug 2007 13:20:00:000	7,271.2002	7,277.1395
20 Aug 2007 13:25:00:000	7,301.9302	7,349.4884
20 Aug 2007 13:30:00:000	7,207.5601	7,277.9576
20 Aug 2007 13:35:00:000	7,190.1899	7,380.2417
20 Aug 2007 13:40:00:000	7,246.0498	7,268.4481
20 Aug 2007 13:45:00:000	7,184.7002	7,154.2097
20 Aug 2007 13:50:00:000	7,353.3701	7,154.2097
20 Aug 2007 13:55:00:000	7,197.3101	7,388.0526
20 Aug 2007 14:00:00:000	7,282.4600	7,227.1819
20 Aug 2007 14:05:00:000	7,278.3999	7,152.4368
20 Aug 2007 14:10:00:000	7,313.4502	7,152.4368
20 Aug 2007 14:15:00:000	7,257.8501	7,270.8989
20 Aug 2007 14:20:00:000	7,206.2798	7,183.3226
20 Aug 2007 14:25:00:000	7,137.3999	7,249.5113
20 Aug 2007 14:30:00:000	7,220.4302	7,242.6558
20 Aug 2007 14:35:00:000	7,135.2300	7,381.8339
20 Aug 2007 14:40:00:000	7,286.6201	7,148.0158
20 Aug 2007 14:45:00:000	7,110.9399	7,148.0158
20 Aug 2007 14:50:00:000	7,131.8501	7,168.6592
20 Aug 2007 14:55:00:000	7,230.7202	7,202.1171
20 Aug 2007 15:00:00:000	7,245.8799	7,288.9226



Figura 80 - Pantalla de la hoja de cálculo de la simulación



Fuente: Gerencia de Fundición

Elaboración: propia

Sin control      Con control

7113.5671	5715.8364
7120.2526	5648.9994
7120.2526	5678.8701
7120.2526	5678.8701
7121.9823	5678.8701
7138.2045	5675.8426
7148.0158	5752.5754
7148.0158	5721.5274
7148.0158	5721.5274
7149.2469	5721.5274
7152.4368	5538.0218
7152.4368	5538.0218
7152.4368	5558.4973
7154.0365	5558.4973
7154.0365	5571.0115
7154.2097	5571.0115
7154.2097	5571.0115
7154.2097	5616.4439
7154.8210	5616.4439

7155.7688	5638.239
7157.4621	5709.6021
7162.6590	5588.1098
7163.3781	5588.1098
7168.6592	5588.1098
7172.2976	5708.3502
7178.0218	5548.1361
7178.0218	5589.0377
7179.9022	5589.0377
7179.9022	5589.0377
7179.9022	5623.1723
7183.3226	5603.7441
7188.1361	5553.1467
7189.6119	5553.1467
7189.6119	5553.1467
7189.6119	5522.659
7193.1467	5515.7688
7193.1467	5632.7906
7193.1467	5632.7906
7198.4973	5632.7906
7198.4973	5697.4008
7201.6383	5481.9823
7202.1171	5622.3732
7211.0115	5622.3732
7211.0115	5622.3732
7211.0115	5612.3017
7220.7553	5740.2282
7221.2903	5682.2492
7227.1819	5682.2492
7228.1098	5682.2492
7228.1098	5628.0107
7228.1098	5722.1337
7228.7293	5647.685
7229.0377	5647.685
7229.0377	5647.685
7229.0377	5708.4983
7242.6558	5708.4983
7243.7441	5517.4621
7249.5113	5532.2976
7249.5113	5672.846
7249.5113	5672.846
7252.3017	5672.846
7252.6547	5509.2469
7252.6547	5498.2045
7252.6547	5549.6119

7256.4439	5549.6119
7256.4439	5549.6119
7262.3732	5473.5671
7262.3732	5588.7293
7262.3732	5480.2526
7263.1723	5480.2526
7268.0107	5480.2526
7268.4481	5671.4767
7270.8989	5735.3385
7272.7906	5539.9022
7272.7906	5539.9022
7272.7906	5539.9022
7277.1395	5523.3781
7277.9576	5561.6383
7277.9576	5721.0846
7277.9576	5721.0846
7278.2390	5721.0846
7287.6850	5655.3037
7287.6850	5514.821
7287.6850	5663.5042
7288.9226	5663.5042
7288.9994	5663.5042
7295.3037	5580.7553
7303.5042	5581.2903
7303.5042	5612.6547
7303.5042	5612.6547
7311.4767	5612.6547
7312.8460	5514.0365
7312.8460	5514.0365
7312.8460	5637.1395
7315.8426	5709.4884
7318.8701	5637.9576
7318.8701	5637.9576
7318.8701	5637.9576
7322.2492	5740.2417
7322.2492	5628.4481
7322.2492	5514.2097
7337.4008	5514.2097
7348.3502	5514.2097
7348.4983	5748.0526
7348.4983	5587.1819
7349.4884	5512.4368
7349.6021	5512.4368
7361.0846	5512.4368
7361.0846	5630.8989

7361.0846	5543.3226
7361.5274	5609.5113
7361.5274	5609.5113
7361.5274	5609.5113
7362.1337	5602.6558
7375.3385	5741.8339
7380.2282	5508.0158
7380.2417	5508.0158
7381.8339	5508.0158
7388.0526	5528.6592
7246.1042	5562.1171