

UNIVERSIDAD NACIONAL DE INGENIERÍA
FACULTAD DE INGENIERÍA MECÁNICA



**OPTIMIZACIÓN DEL CONSUMO Y LA DEMANDA DE
ENERGÍA ELÉCTRICA UTILIZANDO REDES NEURONALES
ARTIFICIALES Y MODELOS DINÁMICOS DE SIMULACIÓN**

TESIS

**PARA OPTAR POR EL TÍTULO PROFESIONAL DE:
INGENIERO MECATRÓNICO**

FRANCO PAJARES CORREA

LIMA – PERÚ

2013

A mis padres y hermanos...

RESUMEN

Este trabajo estudia la aplicación de técnicas modernas de predicción y simulación en la optimización del uso de la energía eléctrica dentro de una planta industrial.

La predicción de la demanda eléctrica es realizada utilizando redes neuronales dinámicas recurrentes, mediante las cuales se intenta prever el comportamiento de la potencia (MW) en el tiempo, empleando patrones definidos mediante un estudio de caso y referencias de trabajos previos. Este módulo ayudará a reorganizar la planificación eléctrica, de tal manera que se reduzcan al mínimo los picos de demanda. 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 de la demanda eléctrica.

La simulación dinámica de una planta industrial es realizada utilizando técnicas modernas de estimación paramétrica, modelado por redes neuronales y ecuaciones matemáticas obtenidas por regresión estadística y modelos previamente elaborados en otros trabajos. Una de las mayores ventajas de la simulación desarrollada es que permite integrar los subsistemas más importantes dentro de un proceso industrial, como son: el eléctrico, el mecánico, el de instrumentación y el energético, de tal manera que se

puedan ensayar diversos escenarios de operación y control, con el fin de evaluar su impacto en todos los subsistemas mencionados. Esto constituye la segunda gran ventaja de la simulación propuesta, debido a que en los simuladores normales sólo se evalúa algún subsistema en particular o algún componente específico del proceso, dejándose de lado la influencia que puede tener un cambio, ya sea por motivos de mejora continua o reingeniería, en todo el proceso en general.

Finalmente se plantean propuestas de ahorro energético en las zonas clave de la planta, simulando su aplicación y evaluando su impacto técnico y económico, tanto a nivel energético, como a nivel del proceso.

La metodología utilizada para el desarrollo del trabajo, está enmarcada en las recomendaciones del Project Management Institute (PMI).

Palabras clave: Optimización de energía, predicción de demanda eléctrica, redes neuronales recurrentes, modelos de simulación dinámica, estimación paramétrica, PMI.

ÍNDICE

ÍNDICE DE FIGURAS.....	vi
ÍNDICE DE TABLAS.....	x
PRÓLOGO	1

CAPÍTULO 1

INTRODUCCIÓN

1.1. Antecedentes	4
1.2. Justificación	7
1.3. Planteamiento del problema	10
1.3.1. Formulación del problema	10
1.3.2. Sistematización del problema	10
1.3.3. Pronóstico	10
1.3.4. Control del pronóstico	11
1.4. Objetivos	11
1.4.1. Objetivo general	11
1.4.2. Objetivos específicos	11
1.5. Metodología de trabajo	12

1.5.1.	Diagrama de flujo	13
--------	-------------------------	----

CAPÍTULO 2

ANÁLISIS DE LA INFORMACIÓN

2.1.	Recolección y validación de la información	16
2.1.1.	Reconocimiento del área de trabajo	16
2.1.2.	Inventario de procesos	20
2.1.3.	Inventario de equipos	23
2.1.4.	Red digital y sistemas de información	23
2.1.5.	Estructura tarifaria eléctrica	26
2.1.6.	Gestión	28
2.2.	Evaluación de la información	29
2.2.1.	Evaluación de la data histórica	29
2.2.2.	Patrones de la RNA	31
2.2.3.	Evaluación tarifaria	33
2.3.	Indicadores	35

CAPÍTULO 3

REDES NEURONALES

3.1.	Fundamentos	38
3.2.	Modelo de la neurona	40
3.3.	Poder computacional	44

3.4.	Topologías neuronales	46
3.5.	Redes recurrentes	46
3.5.1.	Fundamentos	46
3.5.2.	Aplicaciones en el procesamiento de secuencias	48
3.6.	Modelos recurrentes	51
3.6.1.	Modelos recurrentes tradicionales	51
3.6.2.	Modelos de memoria de corto y largo plazo	58
3.7.	Entrenamiento	61
3.7.1.	Algoritmos de entrenamiento supervisado	61
3.7.2.	Predicción numérica con redes recurrentes	66

CAPÍTULO 4

MÓDULO PREDICTOR

4.1.	Diseño de la red neuronal	67
4.1.1.	Definición de parámetros	67
4.1.2.	Diseño de la arquitectura	75
4.2.	Construcción	84
4.2.1.	Programación	84
4.2.2.	Entrenamiento de la red	96
4.2.3.	Interfaz gráfica	105
4.3.	Validación	113
4.3.1.	Plan de pruebas	113

4.3.2.	Contrastación de resultados	115
4.3.3.	Monitoreo	118

CAPÍTULO 5

MÓDULO DE SIMULACIÓN

5.1.	Fundamentos	119
5.2.	Estructura y clasificación de los modelos	121
5.2.1.	Aspectos generales	121
5.2.2.	Estructura del modelo	123
5.2.3.	Modelos paramétricos	126
5.2.4.	Clasificación de los métodos de identificación paramétrica	127
5.3.	Diseño	135
5.3.1.	Definición de fronteras	139
5.3.2.	Definición de subsistemas	140
5.3.3.	Definición de variables	146
5.3.4.	Análisis de caso de uso	148
5.3.5.	Modelo matemático	152
5.4.	Construcción	160
5.4.1.	Diagrama de bloques	160
5.4.2.	Diseño de la interfaz	163
5.4.3.	Especificaciones	165
5.5.	Validación	166
5.5.1.	Plan de pruebas	166

5.5.2. Contratación de resultados	167
-----------------------------------------	-----

CAPÍTULO 6

ANÁLISIS ECONÓMICO

6.1. Oportunidades de ahorro	181
6.2. Evaluación económica	195
6.2.1. Flujo de caja económico	198
6.3. Pruebas y resultados	199

CONCLUSIONES	204
---------------------------	------------

RECOMENDACIONES PARA TRABAJO FUTURO	206
--------------------------------------------------	------------

ANEXOS	208
---------------------	------------

BIBLIOGRAFÍA	212
---------------------------	------------

ÍNDICE DE FIGURAS

- Figura 1.1. Pasos de un programa de gerencia de energía
- Figura 1.2. Evolución Histórica de las Demanda Media y Máxima Mensual de Fundición de Ilo
- Figura 1.3. Evolución del Consumo de Energía en la Fundición Ilo
- Figura 1.4. Diagrama de Flujo del Proyecto de Tesis
- Figura 2.1. Diagrama de flujo de la fundición de Ilo
- Figura 2.2. Diagrama de Pareto de los centros de consumo de la Fundición de Ilo
- Figura 2.3. Red digital de la Fundición de Ilo
- Figura 2.4. Diagrama de bloques del procedimiento de cálculo de pago por demanda y consumo eléctrico de SCC
- Figura 2.5. Ejemplo de ordenamiento y clasificación de Patrones
- Figura 3.1. Función de activación logística (log) en una red neuronal
- Figura 3.2. Esquema de la red parcialmente recurrente de primer orden
- Figura 3.3. Esquema de la red recurrente simple de primer orden
- Figura 3.4. Bloque de memoria temporal con una única celda
- Figura 3.5. Bloque de memoria i -ésimo con dos celdas
- Figura 4.1. Influencia del número de capas en las RNA

- Figura 4.2. Representación de una TDL en tiempo discreto
- Figura 4.3. Principales funciones de activación de las neuronas en una RNA
- Figura 4.4. Estructura general de una red neuronal
- Figura 4.5. Arquitectura de la RNA piloto en formato estándar (Red Estática Feedforward)
- Figura 4.6. Arquitectura de la RNA piloto en formato detallado
- Figura 4.7. Diferencia entre principales redes neuronales dinámicas
- Figura 4.8. Arquitectura de una RNA Dinámica Recurrente NARX simple
- Figura 4.9. Arquitecturas paralela y series-paralela de las redes NARX
- Figura 4.10. Diagrama de bloques de la arquitectura usada en el módulo de predicción
- Figura 4.11. Arquitectura final de la RNA
- Figura 4.12. Diagrama de flujo de los algoritmos de programación para la RNA
- Figura 4.13. Curvas de entrenamiento
- Figura 4.14. Entrenamiento de la RNA NARX con los parámetros óptimos
- Figura 4.15. Ventana inicial de la herramienta GUIDE de Matlab
- Figura 4.16. Pantalla de diseño de la interfaz gráfica
- Figura 4.17. Pantalla de programación de la interfaz gráfica
- Figura 4.18. Pantalla para correr el módulo de predicción
- Figura 4.19. Pantalla inicial del módulo de predicción
- Figura 4.20. Pantalla del módulo de predicción luego del entrenamiento
- Figura 4.21. Demanda predicha Octubre 2007
- Figura 5.1. Métodos de procesamiento de datos para modelamiento
- Figura 5.2. Algoritmo general para el modelamiento de sistemas

- Figura 5.3. Modelos en la visión global de una planta
- Figura 5.4. Diagrama de Bloques General de la Fundición de Ilo
- Figura 5.5. Demanda (KW) de la POX2 en un día de operación normal
- Figura 5.6. Balance de oxígeno de la fundición Ilo
- Figura 5.7. Diagrama de flujo de las plantas de oxígeno
- Figura 5.8. Potencia y porcentaje de apertura de las IGV de las Compresoras MAC en el tiempo
- Figura 5.9. Potencia vs. porcentaje de apertura de las IGV de las Compresoras MAC
- Figura 5.10. Curva característica de un compresor centrífugo
- Figura 5.11. Curvas de compresores centrífugos MAC K11 A&B
- Figura 5.12. Diagrama de bloques inicial para la POX2
- Figura 5.13. Diagrama de bloques final para la POX2
- Figura 5.14. Módulo de simulación final del sistema eléctrico de la Fundición de Ilo
- Figura 5.15. Módulo de simulación final del sistema eléctrico de la Planta de Oxígeno 2
- Figura 5.16. Módulo de simulación de las compresoras de la POX2
- Figura 5.17. Curva flujo volumétrico versus presión de descarga. Compresoras MAC 111 A/B
- Figura 5.18. Resultados de la simulación. Potencias de la POX2
- Figura 5.19. Contrastación de resultados de potencia en la POX2
- Figura 5.20. Variables de proceso de la POX2, luego de la simulación
- Figura 5.21. Variables de producción de la POX2, luego de la simulación
- Figura 5.22. Resultados de la simulación eléctrica de la Fundación de Ilo

- Figura 5.23. Módulo de simulación final de la Fundición de Ilo
- Figura 6.1. Comparación Diseño de las MAC vs. Operación Actual Curva Característica: Presión – Flujo
- Figura 6.2. Condiciones Actuales de Presión de Descarga y Flujo Volumétrico de las MAC
- Figura 6.3. Condiciones actual y de diseño de las MAC. Curvas características Presión – Flujo/Potencia Acople – Flujo
- Figura 6.4. Balance de Oxígeno de la Fundición Ilo. Mes de agosto del 2007
- Figura 6.5. Lazo de Control de las MAC utilizando Variadores de Velocidad
- Figura 6.6. Curva Potencia – Flujo Volumétrico de compresores usando regulación por variadores de velocidad
- Figura 6.7. Flujo de Caja Económico del Proyecto
- Figura 6.8. Ahorros durante el 2008. POX2. MAC 111 A
- Figura 6.9. Ahorros durante el 2008. POX2. MAC 111 B

ÍNDICE DE TABLAS

- Tabla 2.1. Centros de consumo de la fundición de Ilo
- Tabla 2.2. Relación entre número de días y número de muestras mensual
- Tabla 2.3. Fuentes de para la obtención de patrones para la RNA
- Tabla 2.4. Indicadores usados para la evaluación de los resultados
- Tabla 4.1. Parámetros a modificar en el entrenamiento
- Tabla 4.2. Curvas de entrenamiento de la RNA
- Tabla 4.3. Cronograma de toma de datos para la validación de la RNA
- Tabla 4.4. Error cuadrático medio de la RNA. Módulo predicción
- Tabla 4.5. Validación en consumo eléctrico total (total mensual)
- Tabla 4.6. Validación en demanda eléctrica total (máximo mensual)
- Tabla 5.1. Ejemplos de la relación existente entre el objetivo final del modelo (aplicación) y las especificaciones del proceso de identificación
- Tabla 5.2. Plantas simuladas en la tesis
- Tabla 5.3. Variables de la Planta de Oxígeno 2
- Tabla 5.4. Equipos eléctricos de la POX2. Consumos, demandas y carga
- Tabla 5.5. Especificaciones de producción de la planta de oxígeno
- Tabla 5.6. Especificaciones de eléctricas de la planta de oxígeno

- Tabla 5.7. Error cuadrático medio del módulo de simulación
- Tabla 6.1. Potencias y eficiencias eléctricas de los motores de los compresores de la POX2
- Tabla 6.2. Condiciones actual y de diseño de las MAC
- Tabla 6.3. Ahorros usando regulación de flujo a través de variadores de velocidad en US\$ por mes. Compresor MAC K111 A
- Tabla 6.4. Ahorros usando regulación de flujo a través de variadores de velocidad en US\$ por mes. Compresor MAC K111 B
- Tabla 6.5. Ahorros mediante disminución de flujo a través de variadores de velocidad en US\$ por mes. Total mensual
- Tabla 6.6. Ahorros totales en la fundición de Ilo US\$ por mes

PRÓLOGO

La presente tesis está conformada por seis capítulos: introducción, análisis de la información, redes neuronales, módulo predictor, módulo de simulación y análisis económico. Además se presentan las conclusiones, recomendaciones para el trabajo futuro y los apéndices y bibliografía respectiva.

El primer capítulo es el capítulo introductorio, donde se detallan los aspectos más relevantes del por qué se está realizando la tesis. Aquí se muestran los antecedentes o estado del arte, la justificación, el planteamiento del problema, los objetivos, tanto generales como específicos y la metodología empleada en la misma.

En el segundo capítulo, se muestra el proceso realizado para el levantamiento, recolección, validación y análisis de la información necesaria para el desarrollo de la tesis. Aquí se muestran los datos necesarios a conseguir para lograr un procesamiento adecuado tanto en los módulos de predicción como de simulación.

El tercer capítulo trata sobre el fundamento teórico utilizado. Tanto para el caso del módulo de simulación; pero, principalmente, para el caso del módulo predictor de la demanda eléctrica, en la cual se utilizarán redes neuronales dinámicas recurrentes. El marco teórico del porqué de su utilización se encuentra en este capítulo.

En el cuarto capítulo, se presenta el desarrollo del módulo de predicción de demanda y consumo eléctrico para una planta industrial. Aquí, se muestran los pasos realizados para un caso específico de predicción de demanda, enfocándose en el diseño, construcción, programación y validación de la misma. Además se analizan, en este capítulo, diferentes opciones y pruebas de las redes neuronales utilizadas para la predicción.

El quinto capítulo, inicia presentando el fundamento teórico de los modelos de simulación existentes, las estructuras usadas actualmente, así como la base matemática para su uso. Posteriormente, se trabaja con el caso específico del modelo general de una planta industrial, en la cual se busca unificar la simulación de los sistemas más importantes de la misma, como son el termodinámico, de control y eléctrico. Finalmente se presentan los resultados de la simulación realizada.

El sexto capítulo, muestra el análisis económico realizado para el caso específico de una planta industrial. En primer lugar se presentan las oportunidades de ahorro a ser simuladas en el módulo de simulación, posteriormente se presenta la evaluación económica y financiera realizada para dichas pruebas, y luego las pruebas y resultados obtenidos en la realidad, mostrando el ahorro real logrado.

Finalmente, se presentan las conclusiones del trabajo, las cuales van en concordancia con los objetivos específicos de la tesis, mostrados en el Capítulo 1. Además se presentan una serie de recomendaciones, para aquellas personas que quisieran continuar u optimizar el trabajo realizado, dando pautas sobre el camino a seguir. Luego se dejan los anexos respectivos, para posteriormente colocar la bibliografía, la cual ha sido la base de apoyo fundamental de la tesis.

CAPÍTULO 1

INTRODUCCIÓN

La optimización del uso de la energía eléctrica no sólo se ha convertido en una necesidad a nivel económico, sino que, debido al incremento de la preocupación por el cambio climatológico, se ha tornado en una obligación legal. El caso estudiado en la presente tesis corresponde a la Fundición de cobre de Southern Copper Corporation (SCC) ubicada en la provincia de Ilo, departamento de Moquegua, la cual posee un consumo medio mensual de 28 millones de KWh¹.

Southern Copper Corporation, propietaria de Southern Copper Southern Peru es la compañía productora de cobre, que cotiza en bolsa, más grande del mundo en términos de reservas. En base a las ventas del 2007, es la séptima compañía de minería de cobre y la octava compañía más grande de fundición de cobre. También está entre los productores mundiales más grandes de molibdeno, plata y zinc.

Todas sus operaciones mineras se ubican en el Perú y México, y realiza actividades de exploración en el Perú, México y Chile. Posee y opera las siguientes minas y complejos metalúrgicos:

- Cuatro minas a tajo abierto

¹ Promedio obtenido durante el 2008, fecha de la recolección de la data

- Cuajone (Perú). 182,117 toneladas de cobre por año.
- Toquepala (Perú). 177,538 toneladas de cobre por año.
- Cananea (México). 98,503 toneladas de cobre por año.
- La Caridad (México). 124,972 toneladas de cobre por año.
- Tres complejos de procesamiento metalúrgico
 - Ilo (Perú). Fundición y refinería.
 - La Caridad (México). Fundición, refinería y fabricación de barras de cobre.
 - San Luis de Potosí (México). Refinería (zinc) y fundición de cobre.

La fundición de Ilo está ubicada en el sur del Perú, a 17 kilómetros al norte de la ciudad de Ilo, a 121 kilómetros de Toquepala, a 147 kilómetros de Cuajone, y a 1,240 kilómetros de la ciudad de Lima.

La fundición de Ilo proporciona cobre a la refinería que opera como parte de la misma instalación. El cobre producido por la fundición excede la capacidad de la refinería y el cual se vende a refinерías de otras partes del mundo. La capacidad nominal instalada de la fundición es de 1,131,500 toneladas al año. En virtud de un acuerdo con el gobierno del Perú, se ha renovado completamente dicha fundición. Esta modernización se hizo a un costo de \$570 millones y se concluyó en enero de 2007.

1.1. ANTECEDENTES

Existen numerosas técnicas y métodos para la optimización y uso racional del consumo de la energía eléctrica. Entre ellos cabe resaltar el esfuerzo realizado por el

gobierno de los Estados Unidos de América, a través de su departamento de Energía (U.S. Department of Energy) y de la CONAE (Comisión Nacional de Ahorro de Energía) de México.

Estos departamentos muestran una metodología desarrollada a través de los años mediante la cual se busca asistir a los ingenieros de planta, operadores, mantenedores y gerentes a reducir costos en energía, a través de los siguientes pilares:

- Identificación y análisis de las oportunidades de ahorro de energía en los motores.
- Corrección y ajuste del sistema de distribución eléctrica de la planta.
- Corrección del factor de potencia.
- Entendimiento de los contratos de facturación eléctrica.
- Establecimiento de un preventivo y predictivo programa de mantenimiento.

En general, las metodologías actuales para ahorro de energía se basan en el capítulo ‘Elementos de un exitoso programa de gerencia de energía’ del Manual de Gerencia de Energía del departamento de energía de los Estados Unidos. En resumen, dice lo siguiente:

“La gerencia de energía consiste en un bien estructurado esfuerzo colectivo para obtener beneficios energéticos. Para ello se debe: recolectar y organizar la data de costo y consumo de energía; identificación, análisis e implementación de oportunidades de ahorro; y monitoreo de resultados. El programa debe ser realizado sin dejar de lado los programas de mantenimiento o a los departamentos de ingeniería.

Los **10 elementos clave** que son cruciales para el éxito de un programa de gerencia de energía son:

1. Asegurar un muy buen comité de gerencia
2. Elegir al coordinador de energía
3. Obtener la cooperación de los empleados
4. Dirigir encuestas de energía
5. Organizar data de energía
6. Analizar los resultados de las encuestas
7. Determinar metas de ahorro de energía
8. Desarrollar un agresivo y organizado plan de gerencia de energía
9. Implementar cambios de ingeniería
10. Monitorear y evaluar los resultados

El promedio de costos de energía como proporción de los costos de manufactura es cerca del 3%. Históricamente, las plantas industriales han visto los costos de energía, como costos fuera de su control; además de costos fijos que no son lo suficientemente significativos como para prestarles atención. Actualmente, muchas tecnologías de eficiencia energética, técnicas y aproximaciones se han desarrollado y la gerencia de energía está siendo significativamente reconocida por su potencial de mejorar la 'línea inferior'. La Figura 1.1 muestra los pasos sugeridos por el Departamento de Energía de los Estados Unidos, para llevar a cabo un programa de gerencia de energía.

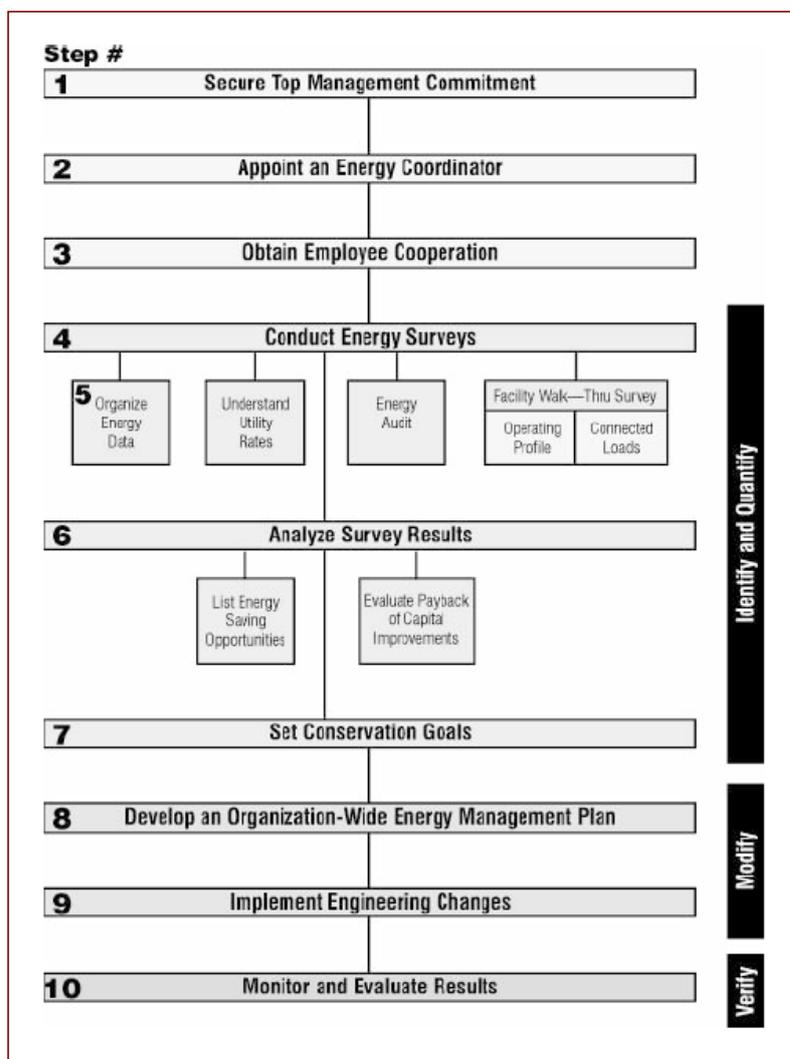


Figura 1.1
Pasos en un programa de gerencia de energía
Fuente: U.S. Department of Energy

1.2. JUSTIFICACIÓN

El presente trabajo se justifica, dentro del marco de la labor del tesista en el proyecto de optimización de energía de la Fundición de Ilo. A continuación, se muestra la justificación del porqué se hace fundamental un estudio de este tipo en dicha planta.

Antes de la modernización², la Fundición de Ilo presentaba una demanda de energía eléctrica media mensual de 19.5 MW y una demanda máxima de 23.5 MW (Figura 1.2), su consumo medio mensual era de 14,000,000 KWh (Figura 1.3). 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 (ver Figura 1.2) y la demanda máxima alcanzó 42 MW.

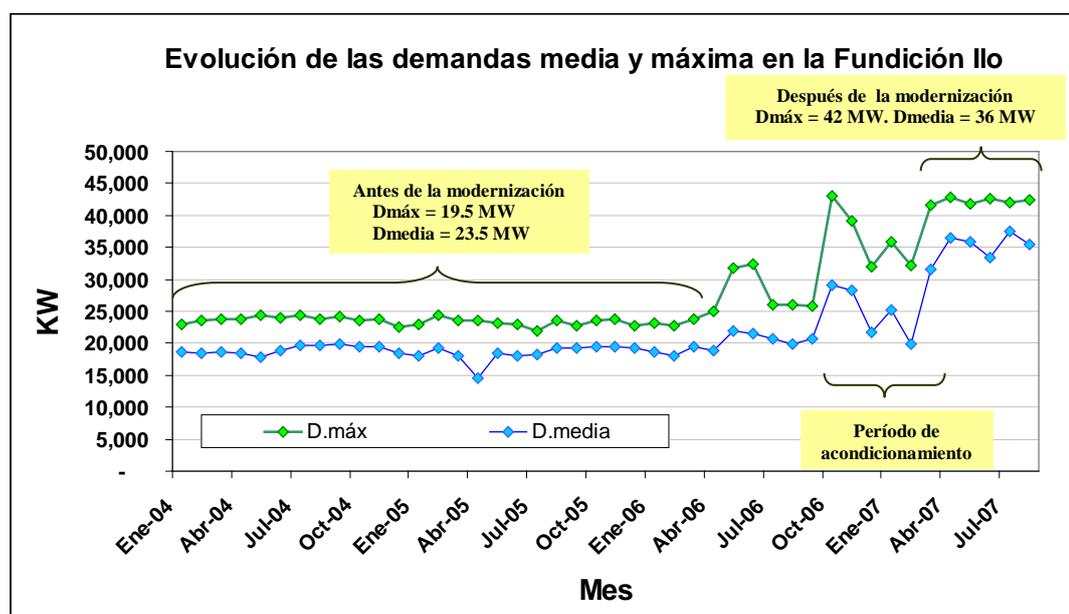


Figura 1.2
Evolución Histórica de las Demanda Media y Máxima Mensual de Fundición de Ilo
Fuente: SCC. Elaboración: Propia

En la nueva planta de fundición, el consumo medio mensual se sitúa en 27,000,000 KWh como se aprecia en la Figura 1.3.

² La Fundición de Ilo pasó por un proceso de modernización entre los años 2003 y 2006, en los cuales se cambió la filosofía de fusión de concentrados de cobre, pasando de un Convertidor CMT a un horno de tecnología ISASMELT.

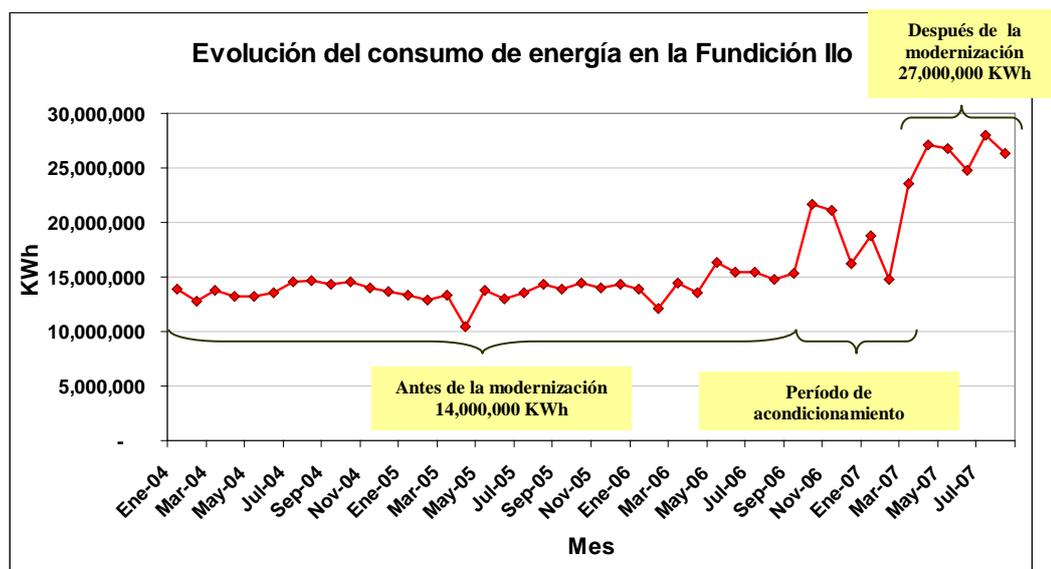


Figura 1.3
Evolución del Consumo de Energía en la Fundición Ilo
 Fuente: SCC. Elaboración: Propia

La demanda máxima aumentó en 18.5 MW, lo que significa un incremento de 78.7% respecto de la planta anterior. El consumo de energía se incrementó en promedio 13,000,000 KWh; es decir, presenta un incremento de 92% respecto del consumo de energía de la planta anterior.

Este incremento de demanda y consumo de energía eléctrica ha elevado considerablemente los montos de facturación³, tanto que ha pasado a ocupar el primer lugar en la estructura de costos de la empresa⁴. La optimización del uso de la energía eléctrica se hace, por tanto, muy necesaria, justificando de esta manera la aplicación del estudio realizado en la presente tesis.

³ La explicación detalla de la estructura tarifaria y la facturación se realizará en el Capítulo II, acápite 2.1.5 y 2.1.3

⁴ Debido a políticas de la empresa no se pueden presentar cifras de su estructura de costos; sin embargo, se presentarán tendencias en el capítulo correspondiente.

1.3. PLANTEAMIENTO DEL PROBLEMA

1.3.1. Formulación del problema

¿De qué manera se puede optimizar el consumo y la demanda de energía en una planta industrial, obteniendo los mejores resultados, sin alterar su producción, o incluso mejorarla?

1.3.2. Sistematización del problema

- a) ¿Cuál es la mejor metodología, para implementar un proceso de optimización energética en una planta industrial?
- b) ¿Qué tan efectivo es el pronóstico de demanda mediante redes neuronales en el ahorro de energía eléctrica? ¿Sirve para controlar los picos de demanda eléctrica?
- c) ¿Cuáles son las estrategias de simulación más adecuadas, para obtener la mayor fiabilidad en el planteamiento de oportunidades de mejora en una planta industrial?

1.3.3. Pronóstico

De mantenerse una situación donde no se aplique ninguna técnica de optimización energética, o alguna técnica mal llevada e implementada, la industria en cuestión perderá competitividad en el mercado, disminuirá sus ingresos y generará sobrecostos de producción.

1.3.4. Control del pronóstico

Es necesario implementar una metodología innovadora para la optimización del consumo y la demanda de energía eléctrica, de tal manera que se puedan ahorrar el máximo de dinero por este rubro, sin alterar la producción.

1.4. OBJETIVOS

1.4.1. Objetivo general

Optimizar el uso de energía eléctrica de una planta industrial, mediante un modelo de pronóstico de demanda, basado en redes neuronales artificiales, y un modelo de simulación dinámica, apoyado en ecuaciones matemáticas, que mejoren la gestión de la demanda y el consumo de energía eléctrica, generando un ahorro económico para la compañía.

1.4.2. Objetivos específicos

- Analizar la información del sistema de energía eléctrico de la planta industrial, incluyendo sus procesos principales: entradas, salidas y sus variables respectivas, así como los proveedores y clientes internos.
- Planificar adecuadamente la demanda de energía eléctrica, mediante un modelo predictivo basado en redes neuronales.
- Reducir el consumo de energía eléctrica de la Fundición de Ilo, mediante la simulación de sus centros de consumo, ensayando

propuestas de ahorro de energía eléctrica, técnica y económicamente factibles, que generen ahorro económico para la compañía.

1.5. METODOLOGÍA DE TRABAJO

Para realizar el presente trabajo se empleó la metodología basada en las recomendaciones del Project Management Institute (PMI), el cual divide el trabajo en 5 entregables finales, según el detalle siguiente:

- Administración del proyecto de tesis, que está referido a la gerencia y control de avances del mismo.
- Análisis de la información, orientado al levantamiento y evaluación de la información, así como los indicadores del proyecto.
- Módulo de predicción, basado en redes neuronales dinámicas recurrentes, que permitirá predecir la evolución horaria futura de la demanda de energía eléctrica en la una planta industrial.
- Módulo de simulación dinámico, que simulará el comportamiento de dicho sistema, modelando los escenarios de trabajo más comunes, y facilitará la identificación de las pérdidas de eficiencia del sistema, sus causas, así como el ensayo de propuestas de ahorro de energía eléctrica.
- Evaluación técnico económica de las propuestas planteadas con el módulo de simulación.

Estos entregables se han dividido en sub-entregables, paquetes de trabajo y actividades, para facilitar la gestión del proyecto. La estructura desglosable del trabajo

(Work Breakdown Structure) se encuentra detallada en un documento bastante similar a la estructura de la tesis, con la diferencia que los entregables presentan una fecha y un costo determinados.

1.5.1. Diagrama de flujo

El desarrollo del proyecto de tesis se inició con el levantamiento de la información, que incluyó el reconocimiento de las áreas, el inventario de procesos y equipos, la estructura de la red digital, el acopio de facturación, en el caso de la Fundación de Ilo en los meses posteriores a su modernización, así como la información sobre sus planes de producción y mantenimiento.

El siguiente paso consistió en evaluar la data histórica contenida en la facturación, la data que proporcionaba el servidor de data en tiempo real Wonderware del PCS (Process Control System) de la empresa, permitiendo determinar los patrones de consumo para construir la red neuronal del modelo predictivo de demanda eléctrica; enseguida se procedió a evaluar la estructura tarifaria y el impacto de los planes de producción y mantenimiento en el sistema de energía eléctrica de la Fundación. Finalmente, se establecieron los indicadores de productividad, energéticos e informáticos.

Este análisis de la información proporcionó los medios necesarios para elaborar el módulo de predicción, facilitando su diseño, construcción y posterior validación.

Al mismo tiempo, se iniciaron los entregables del módulo de simulación, incluyendo los procesos productivos de la Fundación con sus entradas y salidas, así como sus variables respectivas, para elaborar el diseño

del modelo. En la etapa de construcción se modelaron, primeramente, los escenarios de trabajo más comunes; enseguida se modelarán los escenarios de propuestas de ahorro de energía, finalizando con su integración en el último módulo. Esta secuencia de actividades puede resumirse en el diagrama de flujo del proyecto observado en la Figura 1.4.

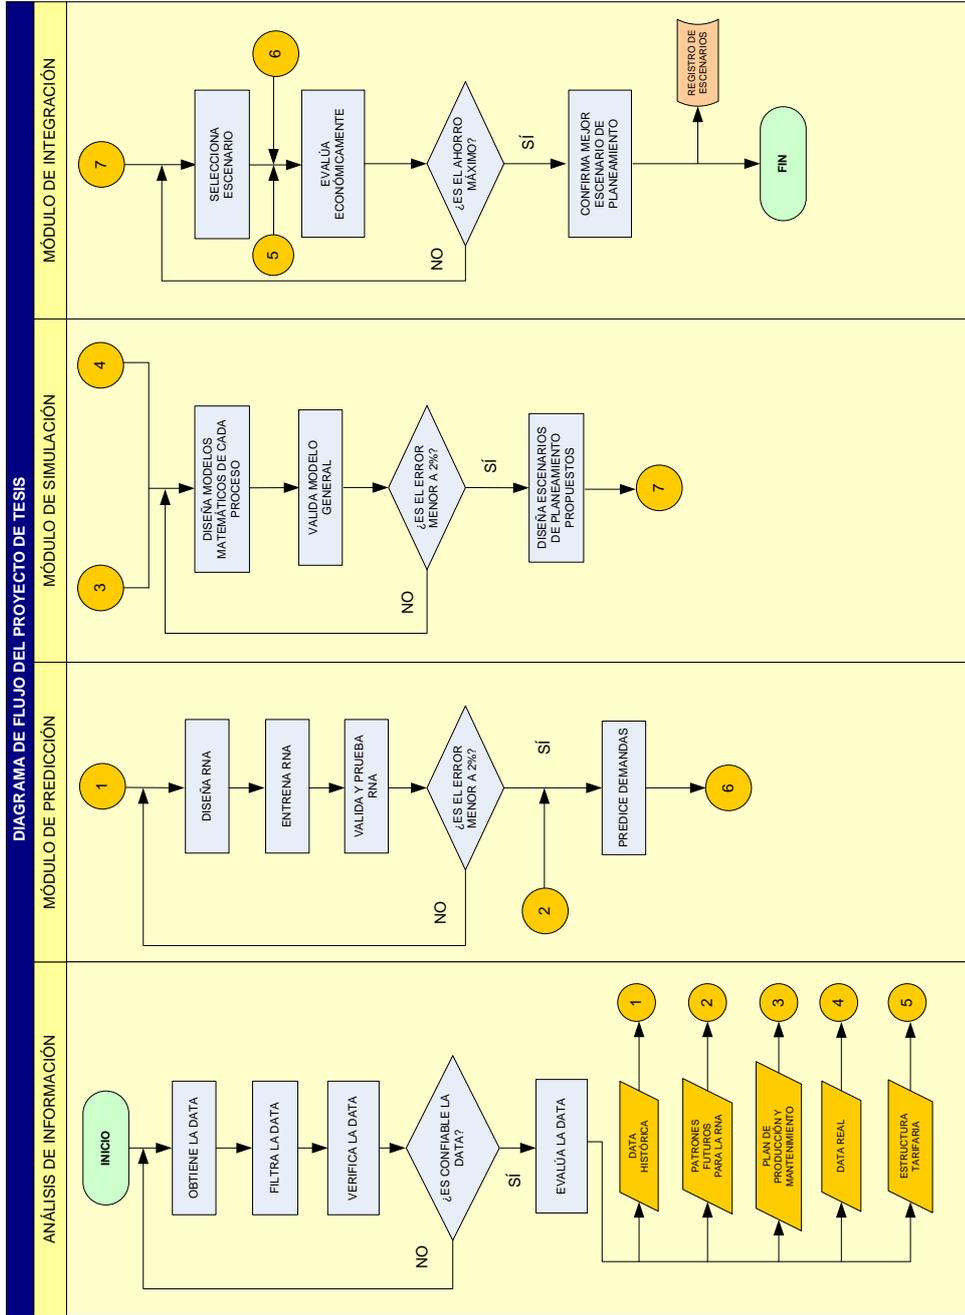


Figura 1.4
Diagrama de Flujo del Proyecto de Tesis
 Fuente y elaboración: Propia

CAPÍTULO 2

ANÁLISIS DE LA INFORMACIÓN

La recolección, evaluación, validación y análisis de la información son los pilares fundamentales de cualquier trabajo de investigación. En este capítulo se detallará el procedimiento de recolección de información, así como su posterior validación y análisis.

2.1. RECOLECCIÓN Y VALIDACIÓN DE LA INFORMACIÓN

2.1.1. Reconocimiento del área de trabajo

Entre el 22 de junio y 16 de julio del 2007 se realizaron entrevistas a cada uno de los jefes de planta de la Fundición de Ilo, obteniéndose información sobre los procesos: diagramas de flujo, variables de entrada y salida, proveedores y clientes de cada uno de ellos. A continuación se muestra de manera general el flujo de operaciones de la planta luego de la modernización y algunas comparaciones con la planta anterior:

1. El concentrado de cobre proveniente de las minas de Toquepala y Cuajone llega por tren al Patio Simón, ubicado a la entrada de la Fundición de Ilo, donde se encuentra una balanza de ferrocarril en la cual se pesa el producto en bruto.
2. Una vez pesado el concentrado, se lo transporta a un Car Dumper⁵, el cual voltea el carro contenedor de material en 180°, lo sacude, para posteriormente trasladarlo a un primer sistema de fajas.
3. A través de este sistema el concentrado llega al área de formación de camas de material, en donde se mezclan los concentrados provenientes de Toquepala con los provenientes de Cuajone, además de prepararse también las camas de los distintos fundentes.
4. Una vez que se tienen preparadas las camas, se pasa el material a otro sistema de fajas transportadoras, las cuales llevan al concentrado y los fundentes a un conjunto 7 tolvas. Las tolvas se dividen de la siguiente manera: 3 para el concentrado, 1 para la conchuela, 1 para el carbón, 1 para la sílice y 1 para el material recirculante.
5. Las tolvas cargan mediante un sistema batch lo que se necesite de cada material, fijando pesos proporcionales a cada uno de ellos, para obtener un producto con la ley que se requiera en el mercado.
6. Luego que se tienen los pesos necesarios de cada material, se los envía a un mezclador de paletas, en donde se homogeniza y combina el concentrado con los fundentes. Además se adiciona agua debido a que

⁵ Car Dumper. Equipo automático capaz de acumular y voltear material, acompañado de un movimiento vibratorio.

en ese instante la humedad es 7%, siendo la necesaria para el proceso de aproximadamente 10%.

7. Una vez homogenizada la mezcla y por medio de una faja adicional, se deja caer el concentrado o mezcla dentro del horno ISASMELT.
8. En el horno ISASMELT (corazón del proceso de Fundición) se realiza el proceso de fusión de concentrados (paso a estado líquido). Este proceso se realiza a través de la entrega de energía en forma de calor. Anteriormente la energía era brindada por hidrocarburos (petróleo); sin embargo, en el proceso de modernización se instaló una lanza dentro del horno que está sumergida con aire enriquecido (hasta un 65% de O₂), de tal manera que se produzca una reacción exotérmica, se aprovechen las características del Azufre para liberar calor, y se pueda tener un ahorro significativo en petróleo.
9. Posteriormente la mezcla líquida (baño fundido) pasa a un sistema de Hornos Rotatorios Permanentes (HRF), en la cual se separa la mata o mate (donde se encuentra el producto valioso: sulfuro de cobre y sulfuro de hierro) de la escoria (óxidos de hierro y otros), para posteriormente, en ollas especiales ser transportada a los convertidores.
10. En los convertidores Pierce – Smith, una vez con el mate en estado líquido, se procede a insuflar aire, de tal manera que se produce la oxidación del hierro y se obtiene el **cobre Blíster**. Sin embargo, se debe tener presente que la escoria obtenida del proceso aún presenta de 3 a 4% de Cobre, lo cual es bastante cantidad, por tal motivo se procede a

recircularla a los convertidores, pasando previamente por un horno de limpieza de escoria.

11. El cobre Blíster se envía a 2 hornos de ánodos en los cuales existen dos procesos químicos marcadamente definidos. El primero es un proceso de oxidación, en donde se trata de eliminar todo el azufre que se pueda (se reduce de 300 ppm a 30 ppm de azufre). Y el segundo es el de moldeo de los ánodos, para luego pasar a refinería. Aquí finaliza la etapa de fundición y obtención de los ánodos de cobre, producto principal de la Fundición de Ilo. Los siguientes ítems, tratan de los demás productos de la fundición.
12. Los gases provenientes del proceso de fusión (del horno ISA), pasan primero a un sistema de enfriamiento en un caldero, en el cual se bajan las temperaturas de 1200 °C a 350 °C, para luego pasar a un precipitador electrostático, cuyo objetivo es atrapar los polvos nocivos del proceso de fusión y el cual a su vez consume gran cantidad de energía, ya que utiliza grandes campos magnéticos.
13. Posteriormente los gases de escape del horno ISA, pasan por un ventilador ID a un ducto de mezcla, en el cual se combinan con los gases de escape provenientes de los Convertidores, y así poder pasar a las plantas de ácido sulfúrico 1 y 2, en donde se obtiene ácido sulfúrico, subproducto principal de la planta.
14. La escoria de descarte se envía a unos botaderos especiales, teniendo todos los cuidados ambientales del caso.

En la Figura 2.1, se muestra el diagrama de flujo general de la Fundición de Ilo.

2.1.2. Inventario de procesos

Los procesos de la Fundición de Ilo, fueron seleccionados de acuerdo a la capacidad para identificar sus fronteras, variables de entrada y salida, clientes y proveedores, así como a partir de la información de consumo y demanda eléctrica disponible de cada uno de ellos. Cada uno de estos procesos, al ser parte de la cadena productiva y demandar una determinada cantidad de energía eléctrica, fueron considerados posteriormente como centros de consumo. En la Tabla 2.1 se muestran los centros de consumo identificados de la Fundición de Ilo.

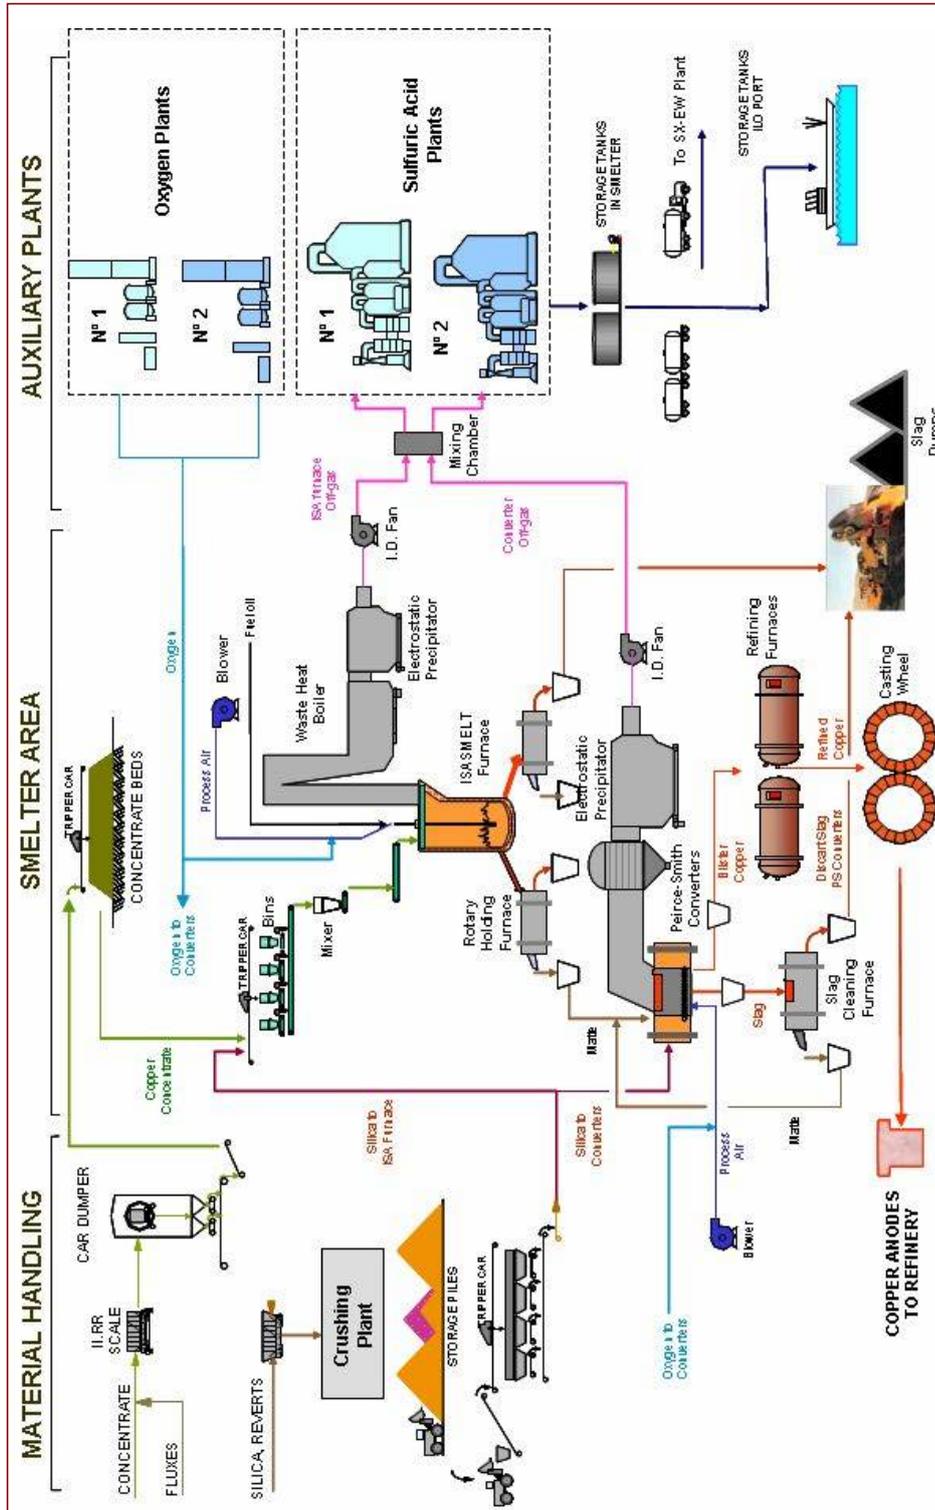


Figura 2.1
Diagrama de flujo de la Fundición de Ilo
Fuente: SCC

Tabla 2.1
Centros de consumo de la Fundición de Ilo

N°	Descripción
1	Proceso de Planta de Cal
2	Proceso de Planta de Ánodos
3	Proceso de Plantas de Ácido
4	Proceso de Plantas de Oxígeno
5	Proceso de Planta de Efluentes
6	Proceso de los Convertidores Peirce-Smith y Hornos de Limpieza
7	Proceso de Preparación de Minerales
8	Proceso de Preparación de Fundentes
9	Proceso de Horno ISASMELT y Hornos RHF
10	Proceso de Toma de Agua de Mar
11	Proceso de Planta Desalinizadora
12	Proceso de Planta de Potabilización
13	Proceso de Distribución de Aire para Procesos
14	Proceso de Manejo de Gases y Polvos

Fuente: Reportes de entrevistas SCC

Elaboración: Propia

Luego del estudio inicial de cada uno de estos procesos, se procedió a clasificarlos teniendo como criterios, en primer lugar, su consumo histórico de energía eléctrica, y luego, su importancia en el proceso productivo.

En la Figura 2.2 se muestra el diagrama de Pareto de consumo eléctrico por centro de consumo, obtenido luego de la recolección de la información del área de Sistemas de Potencia y el servidor ION de energía que posee la compañía.

En dicha Figura se observa que los centros de consumo que mayor energía consumen son los las plantas de oxígeno 2 (33.19%) y de oxígeno 1 (10.15%), plantas de ácido 2 (17.23%) y de ácido 2 (5.85%), convertidores (7.53%), manejo de gases (6.24%) y toma de agua de mar (5.42%). Por tal

motivo se realizará un análisis detallado en dichas plantas, pues presentan las mayores oportunidades de ahorro.

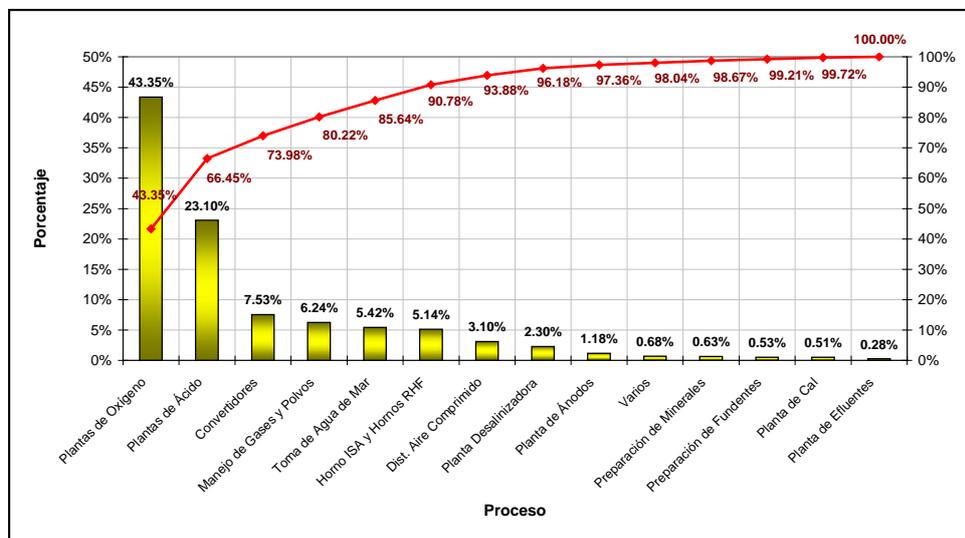


Figura 2.2
Diagrama de Pareto de los centros de consumo de la Fundación de Ilo
Fuente: Reportes Sistema de Potencia. SCC
Elaboración: Propia

2.1.3. Inventario de equipos

Los equipos más importantes de la Fundación de Ilo, desde el punto de vista eléctrico, están clasificados de acuerdo a los medidores colocados en cada uno o en un grupo específico de ellos. El **Anexo 1** muestra un ejemplo de clasificación de los equipos utilizados, su medidor, el centro de consumo al cual pertenecen, y la planta donde operan.

2.1.4. Red digital y sistemas de información

La arquitectura de red en la Fundación de Ilo tiene tres niveles en la estructura de la comunicación general de la planta. En cada nivel, ocurre la

transferencia de información entre los equipos conectados y la transferencia entre cada nivel por medio de servidores redundantes de comunicaciones.

La comunicación se realiza por medio de interfaces para efectuar los procesos de control y monitoreo de las diferentes fases metalúrgicas. Servidores de bases de datos apropiados con sistemas operativos Windows, vía comunicación redundante Ethernet y protocolos como OPC y XML logran la conexión entre los sistemas descritos.

Las redes de SPCC son las siguientes:

Red de control de procesos. Un sistema de control de procesos (PCS) es un sistema digital de control y monitoreo de procesos en tiempo real, basada en una arquitectura distribuida, redundante y abierta. Administra cerca de 10,000 señales de entradas y salidas por medio de la acción de dos redes:

Red de controladores lógicos programables (PLC). Presenta 40 PLC interconectados con un servidor OPC redundante para el intercambio de información con otros niveles. En cada PLC están conectados sensores, actuadores, por medio de buses de campo tales como Foundation Fieldbus, Profibus DP, Hart, Modbus y Devicenet, reemplazando sistemas de conexión alambrados y mejorando la eficiencia del control de los procesos y la calidad del producto.

Red de sistemas de control distribuido (DCS). Presenta 34 DCS conectados a la red con un servidor OPC redundante para tener la capacidad de gestión de los recursos y bienes de planta.

Red de gestión ILAN. Interconecta la red de control de procesos con la red administrativa. Permite la recepción de información a través de servidores redundantes en el sistema de información de planta, en donde residen los softwares de gestión y planeamiento de los recursos. Así mismo, la red ILAN, por medio de un servidor redundante, intercambia información con la red LAN administrativa corporativa (LAN/WAN).

En este nivel se encuentra el servidor de base de datos Wonderware, que permite la visualización de hasta 3000 tags o variables de proceso estratégicas, en línea (discreta y analógica).

Red administrativa. En donde residen los software de administración, logística, costos, mantenimiento y comunicaciones Intranet, entre otros.

Por medio de interfaces apropiados, la red LAN Industrial (ILAN) recibe información estadística de la Red LAN Administrativa (LAN/WAN) por un lado y por el otro, información de procesos en tiempo real del PCS.

En la Figura 2.3 se muestra el esquema de la red digital de la Fundación de Ilo, detallando las interconexiones y los servidores existentes.

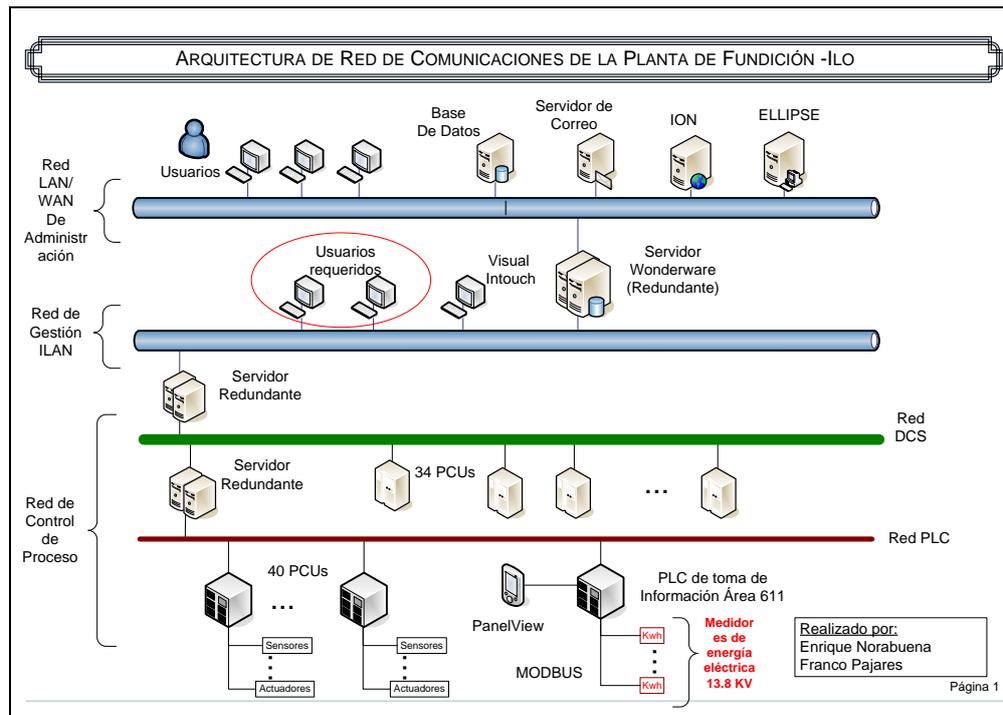


Figura 2.3
Red digital de la Fundición de Ilo
Fuente: SCC. Elaboración: Propia

2.1.5. Estructura tarifaria eléctrica

El pago final de SCC por el uso de la energía eléctrica, se basa en las cláusulas vigentes en el contrato suscrito entre la empresa y la compañía proveedora, responsable de la generación y distribución de la electricidad. El pago está compuesto por la suma de 2 cargos o pagos principales:

- **CARGO POR CAPACIDAD O DEMANDA⁶**
- **CARGO POR ENERGÍA O CONSUMO⁷**

⁶ La demanda eléctrica en la facturación es llamada capacidad. Se refiere a la potencia instantánea tomada cada 15 minutos por los medidores eléctricos de facturación en KW.

⁷ El consumo eléctrico en la facturación es llamado energía. Se refiere a la cantidad de energía consumida durante el mes en curso, sus unidades están en KWh.

A su vez estos 2 cargos principales se pueden dividir cada uno en **Cargo Base** y **Cargo Adicional**, resultando de esta manera 4 los cargos principales que se consideran en la facturación:

- **Cargo por capacidad base**
- **Cargo por capacidad adicional**
- **Cargo por energía base**
- **Cargo por energía adicional**

Cada uno de estos cargos es calculado dependiendo de índices económicos específicos. Los factores de facturación que más fluctúan en periodos cortos de tiempo y que influyen en gran medida en el pago final a realizar son los involucrados en la generación de la electricidad, tales como precio promedio mensual de R500, de Diesel 2 y principalmente el carbón. Otro factor a tomar en cuenta es el tipo de cambio, ya que de acuerdo a Osinerg, algunos precios establecidos por ley se encuentran en soles, por lo que se deben pasar a dólares. Dentro de los parámetros constantes en periodos largos, tenemos aquellos definidos por contrato o por periodo de facturación, razones iniciales de energía o capacidad, precios iniciales de insumos para la generación eléctrica y demás estipulados en el contrato.

En la Figura 2.4 se presenta el diagrama de bloques del procedimiento de cálculo de pago de SCC a la empresa proveedora. Las variables en este caso no se detallan, debido al carácter privado del contrato.

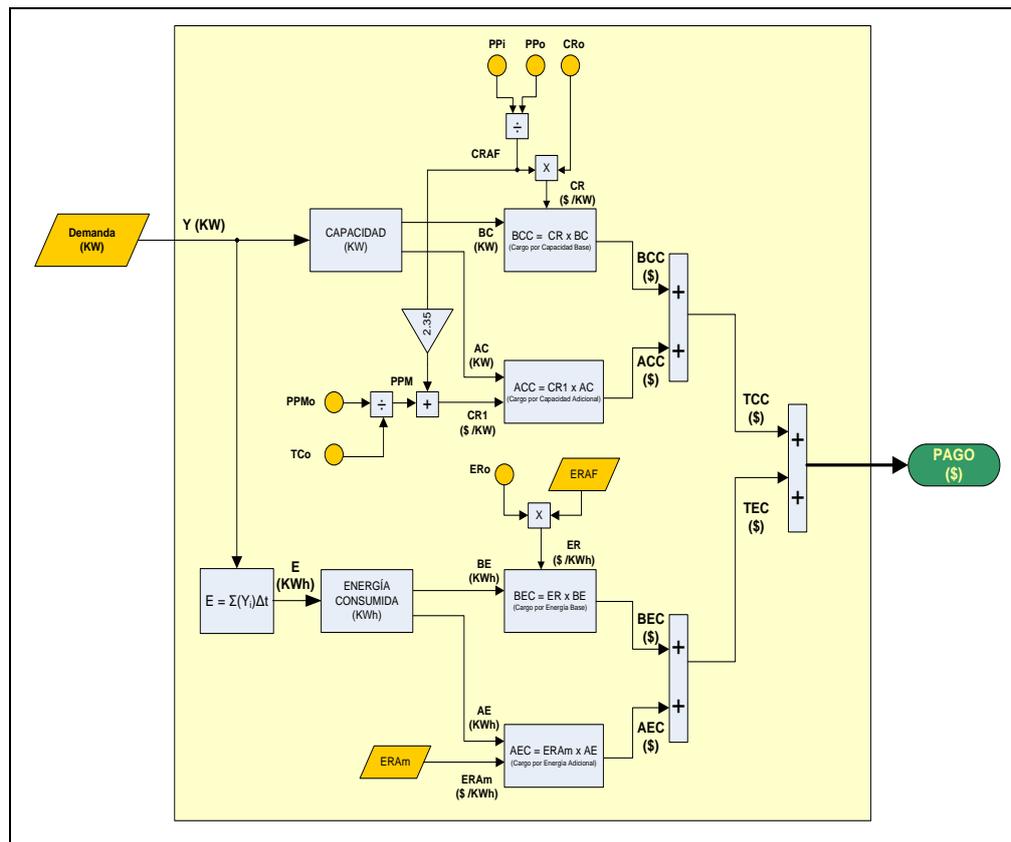


Figura 2.4
Diagrama de bloques del procedimiento de cálculo de pago por
demanda y consumo eléctrico de SCC
 Fuente: SCC. Elaboración: Propia

2.1.6. Gestión

La gestión de la planta está referida al planeamiento de producción y al planeamiento del mantenimiento. En el caso de la Fundación de Ilo, la producción es continua, deteniéndose solamente durante las paradas programadas por mantenimiento en cada área, o por la parada de mantenimiento general realizada anualmente.

La gestión de estos planes, es realizada por las gerencias de operaciones y mantenimiento respectivamente. Este aspecto es muy

importante, ya que permitirá evaluar escenarios de variaciones tanto en la predicción, como en la simulación de la planta.

2.2. EVALUACIÓN DE LA INFORMACIÓN

Una vez obtenidas las fuentes de información, se procedió a la selección, clasificación y evaluación de la misma. En primer lugar se evaluó la data histórica de consumo y demanda eléctrica en la planta, clasificándola y organizándola de tal manera que quede lista para su procesamiento. Posteriormente se obtuvieron todas las posibles variables de producción necesarias para el entrenamiento de la red neuronal artificial (RNA) del módulo de predicción y el modelamiento matemático del módulo de simulación. Finalmente se obtuvo toda la información tarifaria necesaria para estimar valores a futuro.

2.2.1. Evaluación de la data histórica

Para clasificar y evaluar la data histórica de consumo de energía eléctrica, se recurrió a fuentes confiables y probadas de la empresa. Una de ellas es la data revisada y validada por el departamento de Sistemas de Potencia recolectada entre los años 2004 y 2006, es decir antes de la modernización de la Fundición.

A partir de setiembre del 2006 la data recolectada, perteneció a reportes de consumo, validados entre SPCC y la empresa prestadora de la energía eléctrica, la cual contenía data validada y confirmada por los responsables de cada empresa.

En el caso de los meses en los cuales no existen reportes, la data se obtuvo a partir del servidor de energía ION perteneciente a la empresa. Esta data sin embargo no fue validada.

La data obtenida de estas fuentes se encuentra en unidades de energía (KWh) la cual se muestrea cada 15 minutos ($\Delta t = 1/4$ h), por lo que para pasar a unidades de potencia (KW) se multiplicó el valor de energía instantáneo por 4. La demostración se muestra en las ecuaciones 2.1, 2.2, 2.3 y 2.4:

$$E = \sum_{i=1}^N P(i)\Delta t \quad 2.1$$

$$\sum_{i=1}^N e(i) = \Delta t \sum_{i=1}^N P(i) \quad 2.2$$

$$P(i) = \frac{e(i)}{\Delta t} \quad \Delta t = \frac{1}{4} \text{ h} \quad 2.3$$

Luego:

$$\boxed{P(i) = 4 \times e(i)} \quad 2.4$$

Donde:

$P(i)$: Potencia en el instante 'i' [KW]

$e(i)$: Energía en el instante 'i' [KWh]

E : Energía total mensual [KWh]

Δt : Periodo de muestreo o de toma de datos [h]

N : Número de muestras en un mes

El número de muestras mensual varía de acuerdo al número de días de dicho mes. A continuación se muestra la relación entre mes, número de días y número de muestras:

Tabla 2.2
Relación entre número de días y número de muestras mensual

Mes	Nº días	Nº muestras
Enero	31	2976
Febrero	28 ⁸	2688
Marzo	31	2976
Abril	30	2880
Mayo	31	2976
Junio	30	2880
Julio	31	2976
Agosto	31	2976
Septiembre	30	2880
Octubre	31	2976
Noviembre	30	2880
Diciembre	31	2976

Fuente: Propia

2.2.2. Patrones de la RNA

Los patrones serán definidos a profundidad en la Sección 4.1, sin embargo, sí se puede realizar una aproximación a las fuentes para la obtención de datos. La Tabla 2.3, muestra los departamentos para la obtención de cada uno de los datos.

⁸ En el caso de años bisiestos, el número de días es igual a 29, por lo que el número de muestras es 2784

Tabla 2.3
Fuentes de para la obtención de patrones para la RNA

Patrón	Fuente
1. Calendario	Calendario Normal
2. Producción	Reportes de Producción
3. Demanda anterior	Reportes de Mantenimiento

El procedimiento seguido para la clasificación y ordenamiento de los patrones, se muestra a continuación. La data se ha clasificado de acuerdo a una matriz de 2976 filas por 4 meses (entre abril y julio del 2007), teniendo en cada mes los 8 patrones mostrados en la Tabla 2.3. Todos los valores tanto de calendario, producción o demanda se han normalizado entre 0 y 1, teniendo como referencia los valores máximos en cada caso. Un ejemplo de esto se muestra en la Figura 2.5.

The screenshot shows an Excel spreadsheet with the following structure:

- Header Row 1:** A1: Southern Copper logo; B1: PROYECTO: SISTEMA DE GESTIÓN DE CONSUMO Y DEMANDA DE ENERGÍA ELÉCTRICA PARA LA FUNDICIÓN DE ILO; C1: CLASIFICACIÓN DE PATRONES; D1: 2.2.3
- Header Row 2:** A2: ENTREGABLE: (blank); B2: (blank); C2: (blank); D2: (blank); E2: (blank); F2: (blank); G2: (blank); H2: (blank); I2: (blank); J2: (blank); K2: (blank); L2: (blank); M2: (blank); N2: (blank); O2: (blank); P2: (blank); Q2: (blank); R2: (blank); S2: (blank); T2: (blank); U2: (blank); V2: (blank); W2: (blank); X2: (blank); Y2: (blank); Z2: (blank); AA2: (blank); AB2: (blank); AC2: (blank); AD2: (blank); AE2: (blank); AF2: (blank)
- Source:** Fuente: \\Smeta15\Resumen
- Table Headers:**
 - Row 7: Time
 - Row 8: m s d h q An As Os Y
 - Row 9: m s d h q An As Os Y
 - Row 10: m s d h q An As Os Y
 - Row 11: m s d h q An As Os Y
 - Row 12: m s d h q An As Os Y
 - Row 13: m s d h q An As Os Y
 - Row 14: m s d h q An As Os Y
 - Row 15: m s d h q An As Os Y
 - Row 16: m s d h q An As Os Y
 - Row 17: m s d h q An As Os Y
 - Row 18: m s d h q An As Os Y
 - Row 19: m s d h q An As Os Y
 - Row 20: m s d h q An As Os Y
 - Row 21: m s d h q An As Os Y
 - Row 22: m s d h q An As Os Y
 - Row 23: m s d h q An As Os Y
 - Row 24: m s d h q An As Os Y
 - Row 25: m s d h q An As Os Y
 - Row 26: m s d h q An As Os Y
 - Row 27: m s d h q An As Os Y
 - Row 28: m s d h q An As Os Y
 - Row 29: m s d h q An As Os Y
 - Row 30: m s d h q An As Os Y
 - Row 31: m s d h q An As Os Y
 - Row 32: m s d h q An As Os Y
 - Row 33: m s d h q An As Os Y
 - Row 34: m s d h q An As Os Y
 - Row 35: m s d h q An As Os Y
 - Row 36: m s d h q An As Os Y
 - Row 37: m s d h q An As Os Y

Figura 2.5
Ejemplo de ordenamiento y clasificación de Patrones
 Fuente: Reportes de producción y sistemas de potencia (SCC)
 Elaboración: Propia

Los patrones ordenados y clasificados, se encuentran dentro de un archivo Excel, propiedad de la compañía.

2.2.3. Evaluación tarifaria

De acuerdo al acápite 2.1.5 ‘Estructura tarifaria eléctrica’, los parámetros económicos que afectan el pago mensual por consumo y demanda eléctrica se clasifican en:

- Factores variables en periodos cortos
- Factores constantes en periodos largos

Factores variables en periodos cortos

Dentro de los parámetros variables en el tiempo, de la facturación, que se deben monitorear constantemente para obtener un buen cálculo del pago final a realizar están los siguientes:

- Precio Promedio del Residual 500 (Bi)
- Precio Promedio del Diesel 2 (Di)
- Precio Promedio del Carbón (Ci)
- Tipo de cambio (USD\$ a S/.) promedio de precios por banco
- Precio de Potencia Punta Inicial (definido por OSINERG)
- Factor de carga mensual

Factores constantes en periodos largos

Los parámetros que permanecen invariantes por periodos largos o por periodos de facturación son los siguientes:

- Precio Promedio del Residual 500 de contrato (Bo)
- Precio Promedio del Diesel 2 de contrato (Do)
- Precio Promedio del Carbón de contrato (Co)
- Razón Inicial de Capacidad Base (CRo)
- Razón Inicial de Energía Base (ERo)
- Factor de Periodo de Facturación (PPO)
- Coeficientes del cálculo del ERAF (A, B, C y D) – contrato.

El procedimiento para obtener y analizar la data de la estructura tarifaria es el siguiente.

- Primero se obtiene la facturación de los últimos 12 meses a la fecha en la que se realiza la tesis y se la almacena para obtener tendencias.
- Luego basado en modelos dinámicos, se proyectan los valores correspondientes a los próximos 12 meses.

Toda esta información es importante, debido a que permitirá estimar los costos por consumo y demanda de energía, así como los ahorros obtenidos luego de la aplicación de las herramientas presentadas en esta tesis.

2.3. INDICADORES

Se han definido 6 indicadores, clasificados en 2 grupos. El primero de ellos está referido a la productividad; es decir, la producción de cada planta respecto de la energía consumida. El segundo grupo comprende indicadores energéticos, como demanda adicional respecto de demanda base y energía adicional con relación a energía base. En la Tabla 2.4 se muestra la lista de indicadores completa, así como su descripción.

Tabla 2.4
Indicadores usados para la evaluación de los resultados

	INDICADOR	RATIO	DESCRIPCIÓN
PRODUCTIVIDAD	11	C/E	Productividad de Concentrado
	12	An/E	Productividad de Ánodos
	13	Ac/E	Productividad de Ácido
	14	Ox/E	Productividad de Oxígeno
ENERG.	15	DA/DB	Razón de Capacidades
	16	EA/EB	Razón de Energías

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)

Los indicadores han sido elegidos debido a su facilidad de evaluación. Esto se da, debido a que si sólo se considera la disminución energética, sin tener en cuenta los posibles problemas productivos que dicha disminución podría causar, se estaría incurriendo en una grave falta a nivel productivo, pudiendo inclusive detener la

producción. En el caso de considerarse sólo la producción, esta podría aumentar de manera aceptable, sin embargo los índices energéticos subirían sin control. Por tal motivo las relaciones entre ambas se hacen vitales, para cualquier proyecto de disminución u optimización energética y/o industrial.

CAPÍTULO 3

REDES NEURONALES

Este capítulo introduce los elementos principales que definen una neurona y la forma en que estas se combinan para constituir redes neuronales y redes neuronales recurrentes. Además de plantear un modelo formal de red neuronal recurrente, que será utilizado en posteriores capítulos, se describen brevemente las principales aplicaciones de este tipo de redes.

Las redes neuronales recurrentes se eligieron frente a otras técnicas, tales como: correlación lineal, correlación no lineal, ecuaciones de espacio estado, filtro de Kalman, lógica difusa, para predecir el consumo de energía eléctrica, debido a la posibilidad de trabajar con un sistema simple de programar y con una arquitectura que permita tener variables recurrentes, es decir, que la data predicha pueda reingresar nuevamente como variable de entrada al sistema.

Si bien es cierto la identificación paramétrica ARX, ARMA u otras se sustenta en la recurrencia, la facilidad de la programación y el entrenamiento de las RNA hicieron optar por este método.

3.1. FUNDAMENTOS

Una **red neuronal** puede verse como una **máquina diseñada** originalmente para modelar la forma en que el sistema nervioso de un ser vivo realiza una determinada tarea. Para lograr este objetivo, una red neuronal está formada por un conjunto de unidades de procesamiento interconectadas llamadas **neuronas**.

Cada neurona recibe como entrada un conjunto de señales discretas o continuas, las pondera e integra, y transmite el resultado a las neuronas conectadas a ella. Cada conexión entre dos neuronas tiene una determinada importancia asociada denominada **peso sináptico** o, simplemente, **peso**. En los pesos se suele guardar la mayor parte del conocimiento que la red neuronal tiene sobre la tarea en cuestión. El proceso mediante el cual se ajustan estos pesos para lograr un determinado objetivo se denomina **aprendizaje** o **entrenamiento** y el procedimiento concreto utilizado para ello se conoce como **algoritmo de aprendizaje** o **algoritmo de entrenamiento**. El ajuste de pesos es la principal forma de aprendizaje de las redes neuronales, aunque hay otras formas posibles⁹.

El artículo de McCulloch y Pitts (1943) se considera como el punto de arranque de la investigación en redes neuronales; este trabajo introdujo también la teoría de autómatas finitos como modelo computacional. McCulloch y Pitts propusieron un modelo simplificado de la actividad nerviosa real en el que cada neurona de una red neuronal podía activarse o desactivarse en función de lo que hicieran las neuronas conectadas a ella. Debido a que una neurona solo podía estar activada o desactivada, la capacidad computacional de la red completa se define en términos del conjunto de predicados lógicos que es capaz de computar. En este

⁹ Por ejemplo, la modificación del número de neuronas o de la forma de conectarlas.

artículo ya aparecen redes neuronales recurrentes, a las que se denomina redes **con ciclos**.

Unos años después, Kleene (1956) reformuló algunos de estos resultados e introdujo una notación más compacta y general. En su artículo se define el concepto de **expresión regular** (allí llamado **evento regular**), tan importante para la teoría de lenguajes actual y sus aplicaciones. A partir de ahí, el campo de las redes neuronales y el de la teoría de lenguajes comienzan a tomar caminos separados. De hecho, el segundo acaparó una creciente atención desde entonces hasta nuestros días, mientras que el primero quedó prácticamente olvidado a raíz del trabajo de Minsky y Papert (1969). Salvo algunos trabajos aislados (Werbos, 1974), las redes neuronales quedan relegadas a un segundo plano hasta la llegada de los ochenta.

Las redes neuronales destacan por su estructura fácilmente paralizable y por su elevada capacidad de **generalización** (capacidad de producir salidas correctas para entradas no vistas durante el entrenamiento). Otras propiedades interesantes son:

- **No linealidad.** Una red neuronal puede ser lineal o no lineal. Esta última característica es muy importante, especialmente si se intenta modelar sistemas generados mediante pautas no lineales.
- **Adaptabilidad.** Las redes neuronales son capaces de reajustar sus pesos para adaptarse a cambios en el entorno. Esto es especialmente útil cuando el entorno que suministra los datos de entrada es *no estacionario*, es decir, algunas de sus propiedades varían con el tiempo.
- **Tolerancia ante fallos.** Una red neuronal es tolerante ante fallos en el sentido de que los posibles fallos operacionales en partes de la red solo afectan débilmente al rendimiento de esta. Esta propiedad es debida a la

naturaleza distribuida de la información almacenada o procesada en la red neuronal.

3.2. MODELO DE LA NEURONA

En el modelo más habitual de neurona se identifican cinco elementos básicos para la j -ésima neurona de una red de tiempo discreto:

Un conjunto de n señales de entrada $z_i(t)$, $i = 1..n$, que suministran a la neurona los datos del entorno; estos datos pueden ser externos a la red neuronal, pertenecientes a la salida de otras neuronas de la red, o bien correspondientes a la salida anterior de la propia neurona.

- Un conjunto de **sinapsis**, caracterizada cada una por un **peso** propio $W_{ji}(t)$, $i = 1..n$. El peso W_{ji} está asociado a la sinapsis que conecta la unidad i -ésima con la neurona j -ésima.
- Un **sesgo** W_j cuya presencia aumenta la capacidad de procesamiento de la neurona y que eleva o reduce la entrada a la neurona, según sea su valor positivo o negativo.
- Un **sumador** o **integrador** que suma las señales de entrada, ponderadas con sus respectivos pesos, y el sesgo.
- Una **función de activación** g que suele limitar la amplitud de la salida de la neurona.

Utilizando la notación definida anteriormente se puede describir la operación de una neurona mediante la ecuación que determina su **activación** en el instante $t + 1$:

$$z_j[t + 1] = g\left(\sum_{i=1}^n W_{ji}z_i[t] + W_j\right) \quad 3.1$$

Es habitual, y así se hará normalmente en este trabajo, considerar el sesgo como un peso más de la red y no distinguirlo del resto de pesos sinápticos. Por tanto, mientras no se diga lo contrario, el término **pesos** se refiere indistintamente tanto a W_{ji} como a W_j .

La función de activación es la que define finalmente la salida de la neurona. Las funciones de activación más utilizadas habitualmente son las siguientes:

1. Función identidad. Tiene la forma $g_1(x) = x$ y se utiliza cuando no se desea acotar la salida de la neurona.

2. Función escalón. Adopta la forma

$$g_E(x) = \begin{cases} 1 & x \geq 0 \\ 0 & x < 0 \end{cases} \quad 3.2$$

y proporciona una salida con dos posibles valores. Es habitual encontrarla con el nombre de **función de Heaviside**.

3. Función logística. Las funciones sigmoideas son un conjunto de funciones crecientes, monótonas y acotadas que provocan una transformación no lineal de su argumento. Una de las más utilizadas es la función logística definida por

$$g_L(x) = \frac{1}{1 + e^{-x}} \quad 3.3$$

La función logística está acotada entre 0 y 1. En la figura 3.1 se muestra su representación.

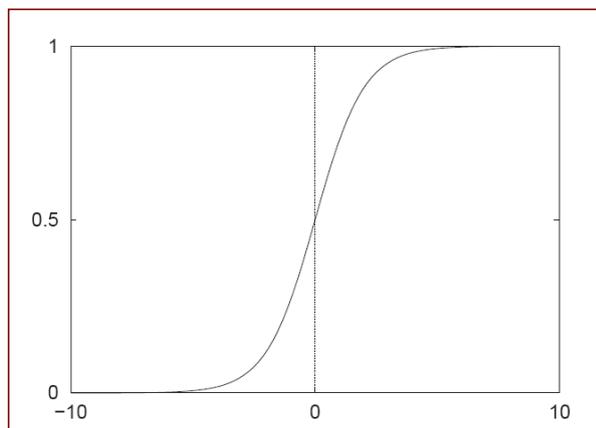


Figura 3.1
Función de activación logística (log) en una red neuronal
 Fuente y elaboración: Propia

4. Función tangente hiperbólica. Otra función sigmoidea es la tangente hiperbólica:

$$g_T(x) = \tanh(x) \quad 3.4$$

En este caso, la función está acotada entre -1 y 1. La función logística y la tangente hiperbólica se relacionan mediante la ecuación:

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad 3.5$$

5. Función de base radial. Las más habituales son funciones gaussianas no monótonas del tipo

$$g_B(x) = \exp\left(\frac{x^2}{-2\sigma^2}\right) \quad 3.6$$

Donde σ define la anchura. La función alcanza su valor máximo cuando la entrada es cero.

3.3. PODER COMPUTACIONAL

El poder computacional de una única neurona es bastante limitado. Si se considera una neurona con función de activación escalón, este poder de computación puede estudiarse desde dos puntos de vista equivalentes: el de la clasificación y el de la representación lógica.

- **Clasificación.** Dado un conjunto de n_p vectores de entrada, cada uno de n componentes, clasificados como pertenecientes a una de entre dos clases, una neurona puede (mediante la asignación correcta de valores a sus pesos y a su sesgo) clasificarlos correctamente¹⁰ únicamente si se cumple la **condición de separabilidad lineal**: los conjuntos de vectores pertenecientes a cada clase deben ser separables por un hiperplano en el espacio n_p -dimensional.
- **Representación lógica.** La fracción de funciones lógicas de n variables que pueden representarse mediante una neurona con función de activación

¹⁰ Si, por ejemplo, se utiliza una función de activación escalón, esta clasificación puede hacerse asignando el valor de salida 1 a los vectores de una clase y el valor 0 a los de la otra.

escalón decrece con n . Por ejemplo, para $n = 1$ las 4 posibles funciones (identidad, negación, siempre cierto y siempre falso) son computables a través de una neurona. Sin embargo, para $n = 2$ ya existen dos funciones no computables (la 'o' exclusiva y su negación). Para n variables, hay un total de 2^{2^n} funciones lógicas. El número de funciones dentro de esas 2^{2^n} que son linealmente separables, es decir, que se pueden implementar con una neurona, $\text{NFL}(n)$, no tiene una expresión exacta para $n > 8$, aunque la siguiente (Horne y Hush 1996) permite acotar su valor:

$$4 \cdot 2^{n(n-1)/2} \leq \text{NFL}(n) \leq \frac{2^{n^2+1}}{n!} \quad 3.7$$

que representa una fracción cada vez menor del total de funciones cuando se aumenta n .

Las limitaciones anteriores se cumplen independientemente de la función de activación utilizada. Si se interconecta un conjunto de neuronas formando una red de manera que la salida de algunas de ellas sea entrada de otras y se utilizan funciones de activación no lineales, pueden superarse estas limitaciones y las redes neuronales resultantes son capaces de emular la máquina universal de Turing (Hopcroft y Ullman, 1979) y de computar, por tanto, cualquier función computable (Siegelmann y Sontag, 1991). La salida de algunas de esas neuronas se convierte en la salida de la red neuronal y al resto de neuronas se las denomina unidades **ocultas** o de **estado**.

El problema que surge entonces es cómo determinar el valor de los pesos y sesgos de la red para poder computar una función determinada. Dado que el espacio

de exploración puede ser enorme, se hace necesario el uso de heurísticas a través de algoritmos de entrenamiento, que no siempre logran dar con una solución adecuada.

3.4. TOPOLOGÍAS NEURONALES

La forma en que se interconectan las neuronas de una red neuronal define un grafo dirigido. Si este grafo es acíclico, la red se denomina **red neuronal hacia adelante** (en inglés, **feedforward network**) y en el caso de que posea ciclos, se denomina **red neuronal recurrente**. En el primer grupo están, entre otros, los perceptrones, las máquinas de vectores soporte y las redes de funciones de base radial (Haykin, 1999).

En el caso de las redes recurrentes, los ciclos existentes tienen un profundo impacto en la capacidad de aprendizaje de la red y las hacen especialmente indicadas para el procesamiento de secuencias temporales; son estas últimas, las redes recurrentes, las que se usan en esta tesis.

3.5. REDES RECURRENTES

3.5.1. Fundamentos

Además de las ya conocidas: redes de tiempo continuo y redes de tiempo discreto, otras posibles clasificaciones dividen las redes neuronales recurrentes en redes de **estado continuo** o de **estado discreto**, según la forma de las funciones de activación empleadas. Según la forma en que se utilicen, cabe también hablar de redes recurrentes **de relajación** y de redes recurrentes **para el procesamiento temporal**. Las primeras evolucionan durante una serie de iteraciones desde un estado inicial a un estado

normalmente estacionario, momento en el que se consulta la salida de la red; la salida de las redes usadas para el procesamiento temporal, por otro lado, se consulta continuamente tras cada iteración.

Entre los grupos anteriores, esta tesis se centra en las redes neuronales recurrentes de tiempo discreto con funciones de activación continuas aplicadas al procesamiento temporal de secuencias. Se trabajará con sistemas dinámicos que poseen un estado que cambia conforme se procesa la secuencia de entrada y que proporciona una secuencia de salida a partir de las activaciones en cada instante de tiempo de las neuronas de salida. Más formalmente, una red neuronal recurrente de tiempo discreto (RNR a partir de ahora) de las que se van a considerar en esta tesis puede verse (Carrasco 2000; Forcada y Gori 2001) como una séxtupla $N = (X, U, Y, g_X, g_Y, x_0)$, donde:

- $X = [S_0, S_1]^{n_x}$ es el espacio de estados de la RNR. S_0 y S_1 son los valores que definen el rango de salida de las funciones de activación utilizadas en la función siguiente estado y n_x es el número de unidades de estado.
- $U = \mathfrak{R}^{n_u}$ es el espacio de los vectores de entrada y n_u el número de componentes de la entrada.
- $Y = [T_0, T_1]^{n_y}$ es el espacio de salida de la RNR. T_0 y T_1 definen el rango de salida de las funciones de activación utilizadas en la función de salida y n_y es el número de componentes de los vectores de salida.

- $g_x : X \times U \rightarrow X$ es la función de siguiente estado, que computa un nuevo estado $x[t]$ a partir del estado anterior $x[t-1]$ y la entrada actual $u[t]$.
- g_y es la función de salida, que habitualmente toma una de las dos formas siguientes:
 1. $g_y : X \times U \rightarrow Y$. La salida $y[t]$ se obtiene a partir del estado anterior $x[t-1]$ y la entrada actual $u[t]$; este tipo de redes se conocen como **máquinas neuronales de estados de Mealy**.
 2. $g_y : X \rightarrow Y$. La nueva salida $y[t]$ se obtiene a partir del estado recién alcanzado $x[t]$; estas redes se conocen como **máquinas neuronales de estados de Moore**.
- x_0 es el estado inicial de la RNR, es decir: $x[0]$.

En el acápite 3.6 se muestran algunas topologías neuronales de carácter recurrente; en el acápite 3.7 se describen los algoritmos de entrenamiento más utilizados sobre RNR.

3.5.2. Aplicaciones en el procesamiento de secuencias

A continuación se enumeran, siguiendo a Forcada y Gori (2001), algunas de las tareas relacionadas con el procesamiento de secuencias a las que se han aplicado las RNR. Los elementos de la siguiente lista no son excluyentes, es decir, alguna tarea podría englobarse en más de una categoría.

Predicción de series temporales. Esta es una de las aplicaciones más habituales de las RNR. A partir de la historia pasada de una o más variables, la red neuronal debe proporcionar una predicción lo más correcta posible de su valor futuro. La mayor parte de los estudios de este tipo se centran en series económicas (McCluskey, 1993) o tomadas de fenómenos naturales (Aussem, 1995), pero hay otras aplicaciones como la continuación de melodías inacabadas (Mozer, 1994). Por otro lado, muchas de las tareas que se indican en los siguientes grupos y cualquiera de las abordadas en esta tesis pueden enfocarse como una tarea de predicción.

Procesamiento del lenguaje humano. El análisis sintáctico de frases o el estudio de regularidades en el lenguaje son algunas de las tareas relacionadas con el lenguaje humano (escrito) a las que se han aplicado las RNR (Elman, 1990; 1991).

Ecuilización de canales digitales. Los efectos del canal sobre la señal transmitida en comunicaciones digitales pueden hacer que esta sea irreconocible al llegar al receptor. Se hace necesario, por tanto, el uso de algún tipo de filtro inverso que deshaga estos efectos y proporcione una señal similar a la original. Esta tarea de traducción de señales se conoce normalmente como **ecualización** y varios trabajos se han acercado a ella con RNR (Kechriotis, 1994; Ortiz Fuentes y Forcada, 1997; Cid-Sueiro, 1994).

Codificación del habla. Existe gran cantidad de técnicas para comprimir una señal de voz de manera que pueda ser transmitida por un canal con el menor número de bits por segundo posible (para una calidad de recepción determinada). Algunas de estas técnicas se basan en la llamada **codificación predictiva**; en ella lo que se envía no es la señal, sino la **diferencia** entre su valor real y el valor predicho por un determinado predictor. Si el predictor es bueno, esta diferencia será pequeña y se necesitarán pocos bits para codificarla. Las RNR también han sido usadas como predictores para la codificación del habla (Haykin y Li, 1995).

Reconocimiento del habla. El reconocimiento del habla puede considerarse como una tarea de traducción de secuencias (por ejemplo, cuando se asigna una secuencia de fonemas a una secuencia de vectores acústicos obtenidos mediante el procesamiento de una señal de voz) o como una tarea de clasificación de secuencias (por ejemplo, al asignar una palabra a una serie de vectores acústicos). Existen varias referencias que utilizan RNR para el reconocimiento del habla (Robinson y Fallside, 1991).

Inferencia gramatical. Dado un conjunto de cadenas pertenecientes a un cierto lenguaje, uno de los problemas más estudiados es la inferencia de un modelo (un autómata finito o una gramática independiente del contexto, por ejemplo) que describa de manera correcta ese lenguaje. Este es posiblemente el campo en el que las RNR han proporcionado mejores resultados (Cleeremans, 1989; Castaño, 1995; Carrasco, 2000).

Control de sistemas. Las RNR pueden ser también entrenadas (Puskorius y Feldkamp 1994) para controlar un sistema real de manera que su salida siga un determinado patrón temporal.

3.6. MODELOS RECURRENTE

3.6.1. Modelos recurrentes tradicionales

En este apartado se presentan algunos modelos recurrentes que se pueden considerar “clásicos” (Carrasco, 2000), ya que han sido utilizados en multitud de referencias desde prácticamente los inicios de las RNR.

1. Redes de primer orden

Una de las topologías neuronales más utilizadas en este trabajo es la red recurrente de propagación de errores o red parcialmente recurrente (Robinson y Fallside 1991) de primer orden (RPR), cuya dinámica viene dada por:

$$y_i[t] = g_Y(Y_i[t]) \quad i = 1, \dots, n_Y \quad 3.8$$

$$Y_i[t] = \sum_{j=1}^{n_U} W_{i,j}^{y,u} u_j[t] + \sum_{j=1}^{n_X} W_{i,j}^{y,x} x_j[t-1] + W_i^y \quad 3.9$$

$$x_i[t] = g_X(X_i[t]) \quad i = 1, \dots, n_X \quad 3.10$$

$$X_i[t] = \sum_{j=1}^{n_U} W_{i,j}^{x,u} u_j[t] + \sum_{j=1}^{n_X} W_{i,j}^{x,x} x_j[t-1] + W_i^x \quad 3.11$$

donde g_y y g_x son funciones de activación equivalentes a las de la sección 3.2, n_x es el número de neuronas de estado, n_u es el número de entradas a la red y n_y es el número de neuronas de salida. Un diagrama de la RPR puede observarse en las Figura 3.2.

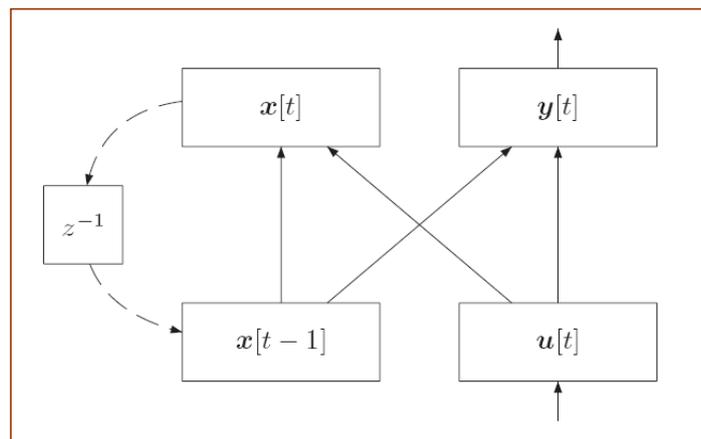


Figura 3.2

Esquema de la red parcialmente recurrente de primer orden

Fuente: Robinson y Fallside (1991). El bloque etiquetado con z^{-1} representa un vector de células de retardo temporal.

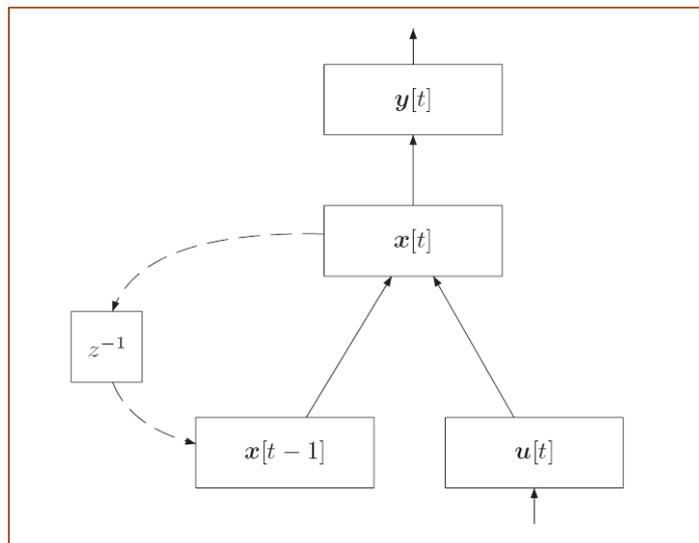


Figura 3.3
Esquema de la red recurrente simple de primer orden
 Fuente: Elman (1990). Juan Antonio Pérez (2002)

A continuación, una breve explicación sobre la notación utilizada para los pesos y sesgos de la red: los súper índices indican el cálculo en el que está implicado el peso: por ejemplo, $W_{i,j}^{y,u}$ indica que ese peso contribuye a determinar la salida y a partir de la entrada u . Por otra parte, W_i^x indica que este peso es un sesgo implicado en el cálculo del estado x . Los subíndices muestran las unidades concretas que se ven afectadas (conectadas) y van paralelos a los superíndices.

Otro tipo de red es la red recurrente simple de primer orden (RRS) propuesta por Elman (1990), que puede observarse en la figura 3.3 y cuya dinámica viene determinada por las ecuaciones:

$$y_i[t] = g_Y(Y_i[t]) \quad i = 1, \dots, n_Y \quad 3.12$$

$$Y_i[t] = \sum_{j=1}^{n_x} W_{i,j}^{y,x} x_j[t] + W_i^y \quad 3.13$$

$$x_i[t] = g_x(X_i[t]) \quad i = 1, \dots, n_x \quad 3.14$$

$$X_i[t] = \sum_{j=1}^{n_u} W_{i,j}^{x,u} u_j[t] + \sum_{j=1}^{n_x} W_{i,j}^{x,x} x_j[t-1] + W_i^x \quad 3.15$$

La red totalmente recurrente (Williams y Zipser, 1989) de primer orden (RTR) viene descrita por:

$$y_i[t] = x_i[t] \quad i = 1, \dots, n_y \quad 3.16$$

$$x_i[t] = g_x \left(\sum_{j=1}^{n_u} W_{i,j}^{x,u} u_j[t] + \sum_{j=1}^{n_x} W_{i,j}^{x,x} x_j[t-1] + W_i^x \right) \quad 3.17$$

normalmente con $n_x \geq n_y$.

Según lo discutido en la sección 3.2, la RRS y la RTR son máquinas de Moore neuronales y la RPR es una máquina de Mealy neuronal. El estado de la red se define como $x[t]$.

2. Redes de segundo orden

La red recurrente simple de segundo orden (RRS2), utilizada por Carrasco et al. (1996) y por Blair y Pollack (1997), viene dada por:

$$y_i[t] = g_y \left(\sum_{j=1}^{n_x} W_{i,j}^{y,x} x_j[t] + W_i^y \right) \quad 3.18$$

$$x_i[t] = g_x \left(\sum_{j=1}^{n_x} \sum_{k=1}^{n_u} W_{i,j,k}^{x,x,u} x_j[t-1] u_k[t] + W_i^x \right) \quad 3.19$$

También puede obtenerse una versión de segundo orden (RPR2) de la RPR. Esta topología ha sido utilizada, entre otros, por Omlin y Giles (1996) y responde a las ecuaciones:

$$y_i[t] = g_y \left(\sum_{j=1}^{n_x} \sum_{k=1}^{n_u} W_{i,j,k}^{x,x,u} x_j[t-1] u_k[t] + W_i^y \right) \quad 3.20$$

$$x_i[t] = g_x \left(\sum_{j=1}^{n_x} \sum_{k=1}^{n_u} W_{i,j,k}^{x,x,u} x_j[t-1] u_k[t] + W_i^x \right) \quad 3.21$$

La red totalmente recurrente de segundo orden (RTR2) propuesta por Giles et al. (1992) se define a partir de:

$$y_i[t] = x_i[t]$$

$$x_i[t] = g_x \left(\sum_{j=1}^{n_x} \sum_{k=1}^{n_u} W_{i,j,k}^{x,x,u} x_j[t-1] u_k[t] + W_i^x \right) \quad 3.22$$

donde, como en la RTR, se suele hacer n_x, n_y .

Según lo discutido en la sección 3.2, la RRS2 y la RTR2 son máquinas de Moore neuronales de segundo orden y la RPR2 es una máquina de Mealy neuronal de segundo orden. El estado de la red se considera, de nuevo, almacenado en $x[t]$.

3. Redes NARX (Nonlinear Autoregressive Exogenous Model)

Las RNR de primer y segundo orden mostradas hasta ahora pueden considerarse de *estado oculto*; el estado de estas redes se almacena en $x[t]$.

Existen otras redes, como la red NARX, que se pueden considerar de *estado visible*, ya que su estado es simplemente una combinación de las entradas y salidas anteriores.

Además de incorporar a la red las $p - 1$ entradas anteriores, las redes NARX1 (Narendra y Parthasarathy, 1990) añaden las ‘q’ salidas anteriores de la red. Una red NARX con orden de entrada ‘p’ y *orden de salida* ‘q’ viene definida por las ecuaciones:

$$y_i[t] = g_Y \left(\sum_{j=1}^{n_z} W_{i,j}^{y,z} z_j[t] + W_i^y \right) \quad 3.23$$

$$z_i[t] = g_Z \left(\sum_{j=1}^{n_u} \sum_{k=1}^p W_{i,j(k)}^{z,u} u_j[t - k + 1] + \sum_{j=1}^{n_y} \sum_{k=1}^q W_{i,j(k)}^{z,y} y_j[t - k] + W_i^z \right) \quad 3.24$$

Se ha usado z_i para las neuronas intermedias y no x_i para evitar confusiones, ya que, como se ha comentado, el estado de las NARX no está en ellas, sino en la ventana de entradas y en la de salidas.

Cuando el estado de la red NARX está formado únicamente por las entradas anteriores de la red, es decir, cuando $q = 0$, se obtiene una red denominada tradicionalmente *red neuronal de retardos temporales* (Sejnowski y Rosenberg, 1987) (TDNN, por el inglés *time-delayed neural network*).

Por otro lado, si eliminamos el conjunto de neuronas intermedias (con activaciones $z_i[t]$) de la red NARX para permitir así la conexión directa entre la entrada y la salida de la red, y usamos la identidad como función de activación para g_Y , obtenemos el modelo de filtro de *respuesta de tiempo infinito al impulso* (IIR, por el inglés *infinite-time impulse response*), ampliamente utilizado en teoría de señales (Oppenheim y Schaffer, 1989; Proakis y Manolakis, 1998) y cuya ecuación es:

$$y_i[t] = \sum_{j=1}^{n_u} \sum_{k=1}^p W_{i,j(k)}^{y,u} u_j[t - k + 1] + \sum_{j=1}^{n_y} \sum_{k=1}^q W_{i,j(k)}^{y,y} y_j[t - k] + W_i^y \quad 3.25$$

Finalmente, si las consideraciones anteriores se aplican a una red TDNN (esto es, si se hace $q = 0$ en la ecuación anterior), se obtiene las ecuaciones de un filtro de *respuesta de tiempo finito al impulso* (FIR, por el inglés *finite-time impulse response*), también muy usado en teoría la señal (Oppenheim y Schaffer 1989; Proakis y Manolakis 1998):

$$y_i[t] = \sum_{j=1}^{n_u} \sum_{k=1}^p W_{i,j(k)}^{y,u} u_j[t - k + 1] + W_i^y \quad 3.26$$

3.6.2. Modelo de memoria de corto y largo plazo

Para comprender el modelo de memoria a corto y largo plazo (LSTM, por el inglés *long short-term memory*) se hace muy necesario conocer el problema del gradiente evanescente, lo cual no es motivo de esta tesis. Este apartado, por tanto, se limitará a presentar la configuración y las ecuaciones que definen el modelo.

El componente básico del modelo LSTM (Hochreiter y Schmidhuber, 1997) es el *bloque de memoria*, que contiene una o más *celdas* de memoria, una *compuerta de entrada* y una *compuerta de salida*. Las compuertas son unidades multiplicativas con activación continua (normalmente dentro del intervalo unidad) y son compartidas por todas las celdas que pertenecen a un mismo bloque de memoria. Cada celda contiene una unidad lineal con una conexión recurrente local llamada *carrusel de error constante* (CEC); la activación del CEC se conoce como el *estado* de la celda.

La Figura 3.4 muestra uno de estos bloques de memoria con una única celda; esta figura es útil también para introducir la notación relativa al modelo que se utilizará a lo largo de la tesis. La Figura 3.5 muestra un bloque de memoria con dos celdas, que comparten las compuertas del bloque.

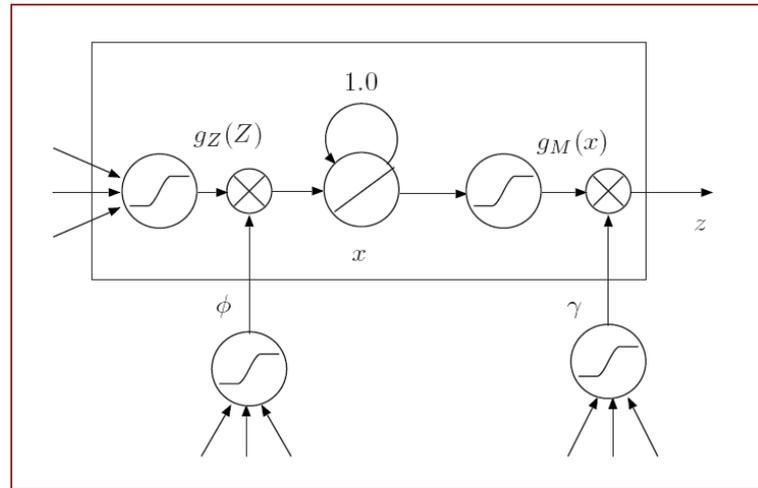


Figura 3.4
Bloque de memoria temporal con una única celda
 Fuente: Juan Antonio Pérez (2002)

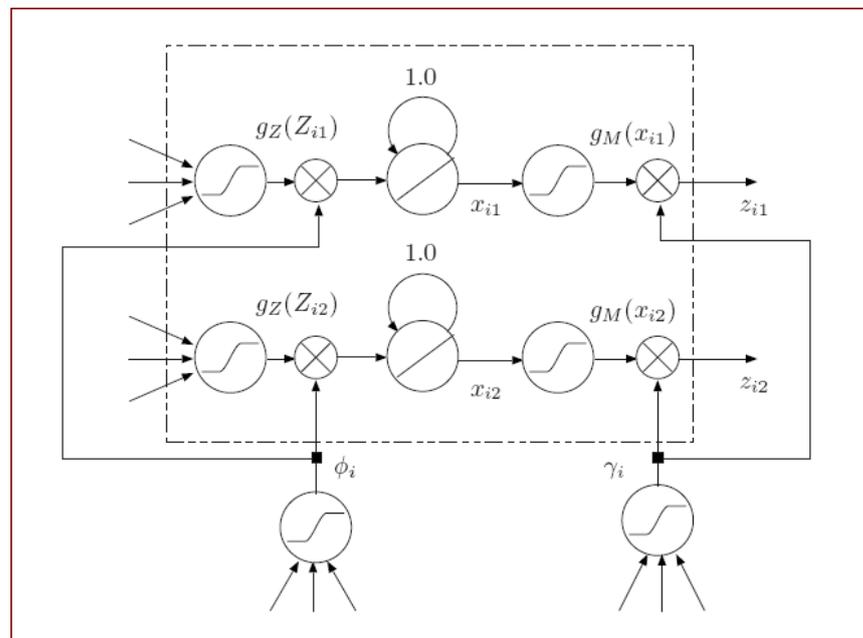


Figura 3.5
Bloque de memoria i-ésimo con dos celdas
 Fuente: Juan Antonio Pérez (2002)

Cada celda recibe como entrada una colección de valores (ponderados mediante los pesos correspondientes) provenientes de la entrada de la red y

de las salidas de todas las celdas del modelo en el instante anterior. La compuerta de entrada se encarga de permitir o impedir el acceso de estos valores al CEC del interior de la celda. La compuerta de salida realiza una acción similar sobre la salida de la celda, tolerando o reprimiendo la difusión del estado del CEC al resto de la red.

Los bloques de memoria configuran una red LSTM como puede verse en la Figura 3.6, donde no se indican los sesgos de las distintas neuronas del modelo. La existencia de las conexiones con pesos $W_{y,u}$ determina la naturaleza de la red según lo discutido en 3.2. Así, si se permite la existencia de esta conexión, la red LSTM se puede considerar como una máquina neuronal de estados de Mealy; si no se permite, la red LSTM puede considerarse como una máquina neuronal de estados de Moore. El estado de la red LSTM está formado por las activaciones de las compuertas, el CEC y las celdas de los bloques de memoria.

Basándonos en la notación ya introducida, a continuación se describe brevemente la correspondiente a la red LSTM. Sean n_U , n_Y , n_M , n_C el número de neuronas de entrada, salida, bloques de memoria y celdas por bloque, respectivamente. La entrada en el instante 't' se denota con $u[t]$ y la salida correspondiente con $y[t]$. La salida de la j-ésima celda del bloque i-ésimo se representa con $z_{ij}[t]$.

Como ya se vio antes, al representar los pesos, los superíndices indican el cálculo en el que está involucrado el peso en cuestión: el " ϕ, z " en $W^{\phi,z}$ indica que el peso se usa para calcular la activación de una compuerta

de entrada (ϕ) a partir de la de una celda (z); el “ γ ” en W^γ indica que el sesgo se usa para calcular la activación de una compuerta de salida. Los subíndices indican las unidades particulares afectadas por el peso y van paralelos a los superíndices.

3.7. ENTRENAMIENTO

Una vez seleccionado el modelo neuronal con el que resolver un determinado problema, surge la cuestión de cómo determinar el valor de los pesos de la red que permiten resolverlo con éxito. Los algoritmos de entrenamiento se encargan de intentar encontrar esta configuración correcta. En este capítulo se muestran algunos de los más utilizados con RNR, principalmente el descenso por el gradiente y el filtro de Kalman extendido desacoplado. Ambos se basan en el cálculo de la derivada de la función de error; dos son las formas más habituales de obtener estas derivadas: el aprendizaje recurrente en tiempo real y la retropropagación a través del tiempo.

3.7.1. Algoritmos de entrenamiento supervisado

Cuando se desea resolver una determinada tarea con la ayuda de una RNR, lo primero que se debe considerar es el tipo de red que se va a utilizar. La elección no es trivial: hay problemas que se resuelven aceptablemente bien con un tipo de red, pero que son muy difíciles (o imposibles) de resolver con otro.

El número de entradas y de neuronas de salida vienen determinados por la naturaleza de la tarea a resolver, por el tipo de secuencias a procesar o por la codificación utilizada para sus elementos. Otros valores como el

número de neuronas de estado o el orden de entrada o salida deberán ser determinados tras experimentar con distintas combinaciones o usar los límites dados en la teoría para algunos tipos de tarea.

A continuación debe entrenarse la red para ajustar sus parámetros libres (los pesos habitualmente). Atendiendo a la forma en que se presentan los datos, los algoritmos de aprendizaje pueden dividirse en dos categorías:

- ***Entrenamiento supervisado.*** En este tipo de algoritmos la red neuronal cuenta con el apoyo externo de un “maestro” que informa de la corrección de la salida producida por la red de acuerdo con la salida considerada correcta.
- ***Entrenamiento no supervisado.*** En este caso no existe tal maestro y la red neuronal debe extraer sin ayuda características de los datos que se le suministra.

Este trabajo se centra en el uso de RNR para la predicción del siguiente elemento de distintas secuencias; por ello, todos los algoritmos de aprendizaje estudiados serán supervisados. Durante el entrenamiento, la entrada al algoritmo será una representación del elemento actual (o del actual y de algunos de los anteriores, si se utiliza una ventana temporal de entradas) y la salida deseada será la representación del siguiente elemento.

Para entrenar la RNR de forma supervisada se necesita normalmente algún tipo de ***medida del error*** $E[t]$ que describa la adecuación de la salida proporcionada por la red al valor deseado. Los parámetros se ajustan intentando minimizar este error.

La función de error más habitual es la función de error cuadrático, definida para el instante t como:

$$E[t] = \frac{1}{2} \sum_{i=1}^{n_y} (d_i[t] - y_i[t])^2 \quad 3.27$$

donde $d_i[t]$ es la *salida deseada* u *objetivo* para la i -ésima neurona de salida en el instante t e $y_i[t]$ es la salida correspondiente de la red.

Una posible forma de encontrar la solución que minimice el valor del error es la búsqueda exhaustiva sobre todas las posibles combinaciones de valores de los pesos (o sobre un conjunto finito lo suficientemente significativo de posibles valores). Evidentemente, esta forma de resolución es intratable en la mayoría de los casos. Si el problema a aprender es sencillo, puede que una estrategia basada en generar aleatoriamente conjuntos de valores para los pesos funcione (Schmidhuber y Hochreiter, 1996). En general, sin embargo, se hace necesaria la utilización de algún tipo de heurística que recorte el espacio de soluciones a explorar; esta es la labor de los algoritmos de entrenamiento.

Aprendizaje en línea y fuera de línea

Supongamos una red neuronal que se está utilizando para el procesamiento de secuencias. Si la red se aplica a la clasificación de secuencias, por ejemplo, el conjunto de entrenamiento contendrá una serie de

secuencias cuya clasificación es conocida de antemano. El algoritmo de entrenamiento debe conseguir que la red “aprenda” estas clasificaciones. Otras veces puede quererse que la red procese una única secuencia en tiempo real.

En algunos casos, la red neuronal se somete a una fase de entrenamiento, tras la cual sus pesos se **congelan**. Durante esta fase a la red se le presentan (normalmente más de una vez) los datos del llamado *conjunto de entrenamiento*. A continuación, esta red neuronal se **evalúa** sobre un nuevo conjunto de datos para determinar la corrección del aprendizaje.

En otros casos, las fases de entrenamiento y evaluación no están tan claramente separadas y la salida de la red se usa simultáneamente como punto de referencia para cambiar los pesos y como producto utilizado en la resolución de la tarea en cuestión.

Cada tipo de procesamiento requiere una estrategia de aprendizaje distinta. Según la forma de actualizar los parámetros libres (pesos y sesgos, normalmente) de la red neuronal, los algoritmos de entrenamiento supervisado pueden dividirse en las siguientes cuatro clases:

- **Entrenamiento en línea.** Puede subdividirse en:
 - **En línea por elementos o en línea puro.** Este tipo de algoritmo se utiliza cuando se pretende que la red trabaje *en tiempo real*, dando una salida lo más correcta posible a los elementos de la secuencia suministrados en cada instante. Es habitual en este caso no distinguir las fases de entrenamiento y

evaluación. Se considera una función de error instantáneo y los pesos se actualizan inmediatamente después de considerar cada elemento. Este tipo de entrenamiento se hace especialmente necesario al tratar con entornos no estacionarios en los que las estadísticas de las fuentes de datos cambian con el tiempo.

- **En línea por secuencias.** En este caso, los pesos se siguen ajustando tras el procesamiento de cada elemento, pero, además, se permite reiniciar el estado de la red en momentos determinados del entrenamiento, normalmente al final de cada secuencia.

- **Entrenamiento fuera de línea.** Los algoritmos pertenecientes a este tipo de entrenamiento pueden a su vez subdividirse en:
 - **Fuera de línea por secuencias.** La actualización de los pesos realizada por el algoritmo se lleva a cabo tras la presentación de cada secuencia. La función de error considera todos los errores instantáneos cometidos sobre cada uno de los elementos de la secuencia.

 - **Fuera de línea por épocas o por lotes.** Los pesos se actualizan una vez presentadas *todas las secuencias*, es decir, únicamente después de ver todo el conjunto de entrenamiento, periodo que se denomina *época*. La función de error considera, por tanto, los errores cometidos sobre todo ese conjunto.

3.7.2. Predicción numérica con redes recurrentes

La forma de utilizar una RNR para la predicción del siguiente elemento de una secuencia numérica es aparentemente sencilla: la muestra $s[t]$ se introduce en las entradas de la RNR (directamente con su valor o bien con un valor normalizado sobre un determinado rango) y se computa con ella la salida correspondiente $y[t]$. Esta salida se considera como una estimación del valor de la siguiente muestra de la señal, esto es, $y[t] = \hat{s}[t+1]$, con lo que el valor de la salida deseada usado en la función de error es $d[t] = s[t+1]$.

La función de activación de las neuronas de salida debe ajustarse adecuadamente al rango de posibles valores de la señal.

CAPÍTULO 4

MÓDULO DE PREDICCIÓN

Este capítulo presenta el análisis, desarrollo, evaluación y monitoreo del módulo de predicción de demanda y consumo eléctrico.

4.1. DISEÑO DE LA RED NEURONAL

4.1.1. Definición de parámetros

Entradas o patrones

Uno de los ítems 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 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. (Murto, 1998; Bao, 1996; Proyecto Indel, 1998)

A continuación se comentarán las variables observadas en las fuentes bibliográficas como posibles factores explicativos de la curva de demanda eléctrica:

1. Condiciones metereológicas

- Temperatura
- Velocidad del viento
- Nubosidad
- Pluviosidad
- Humedad relativa

2. Calendario

- Hora del día
- Día de la semana
- Fin de semana y feriados
- Mes del año

3. Información económica

4. Factores no predecibles

Como se observa de acuerdo a la bibliografía revisada, son numerosos los factores que influyen en la curva de demanda eléctrica. Sin embargo, toda

la información ubicada se refiere a factores que afectan la curva de demanda eléctrica civil y no industrial, por lo que no se podrán utilizar varios de los patrones descritos. En los ítems siguientes se analizarán nuevos patrones que afectan de manera significativa el ambiente industrial y productivo.

Teniendo como base los patrones descritos anteriormente y revisando pequeñas muestras de data histórica de la demanda eléctrica en la Fundición Ilo, se procedió a evaluar la influencia de los distintos patrones, teniendo como prioridad los factores de calendario, ya que son valores fijos y se puede saber con exactitud cuál será su valor en el futuro.

De acuerdo a todo lo descrito, los patrones o entradas a utilizar en el ambiente industrial son:

- **Calendario**

Será un array de vectores de $5 \times N$ elementos, donde 5 son el número de patrones calendario y N es el número de muestras por mes, teniendo como periodo de muestreo 15 minutos.

$N = 2976$ (31 días)

$N = 2880$ (30 días)

Los patrones considerados en este caso son:

- Mes
- Semana
- Día
- Hora

- Cuarto de hora

- **Producción**

Será un vector de $3 \times M$, donde 3 son el número de patrones y M es el número de muestras, teniendo como periodo de muestreo 1 día.

- **Demanda del mes anterior**

Será un vector de $1 \times N$, donde 1 es el único patrón y N es el número de muestras. Nótese que este N es el mismo número de datos correspondiente a la Tabla 2.2.

Salidas o targets

De acuerdo al objetivo del proyecto las salidas serán:

- **Demanda del mes próximo**

Será un vector de $1 \times N$, en donde N es el número de muestras que existen en el próximo mes.

- **Consumo del mes próximo**

Será un valor (1×1) obtenido directamente de la data de demanda predicha.

Capas ocultas

De acuerdo a la bibliografía revisada no existe una metodología específica para determinar el número de capas ocultas en una RNA, sin embargo existen ciertos criterios para el modelamiento de sistemas dinámicos complejos:

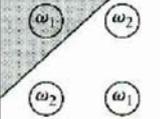
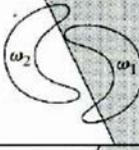
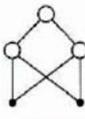
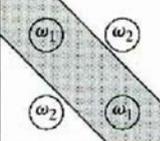
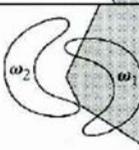
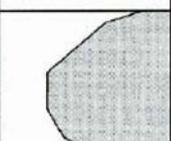
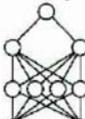
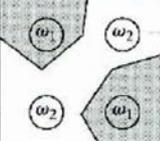
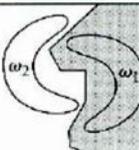
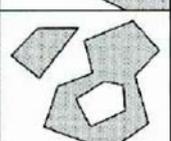
Network structure	Type of decision region	Solution to exclusive-OR problem	Classes with meshed regions	Most general decision surface shapes
Single layer 	Single hyperplane			
Two layers 	Open or closed convex regions			
Three layers 	Arbitrary (complexity limited by the number of nodes)			

Figura 4.1
Influencia del número de capas en las RNA

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

Se nota que a medida que aumentan el número de capas, la identificación en el espacio R^2 se comporta de manera más precisa. Sin embargo, en el espacio R^N con $N > 3$, no se puede establecer que la precisión aumentará a medida que aumentan el número de capas ocultas.

En nuestro caso y basado en la experiencia de modelamiento de sistemas dinámicos complejos se utilizarán 2 capas ocultas, ya que es la que muestra una mejor performance en la predicción a un costo computacional de entrenamiento aceptable

Número de neuronas por capa

La determinación del número óptimo de neuronas de las capas ocultas se ha llevado a cabo mediante un proceso de ensayo y error en el que jugamos con el número de neuronas y el máximo error admisible. En todo

caso, nuestro objetivo será dotar a la red de un número adecuado de neuronas en la capa oculta para que sea capaz de aprender las características de las posibles relaciones existentes entre los datos de la muestra.

Demasiadas neuronas podrían llevarnos a un sobre-ajuste, la red memorizaría el conjunto de datos de entrenamiento y para valores pertenecientes al mismo su precisión sería casi absoluta. Sin embargo si le presentamos valores desconocidos fallaría estrepitosamente, dado que como consecuencia del sobre-ajuste sería incapaz de generalizar. Por otra parte si el número de neuronas en la capa oculta es reducido podremos llegar a una situación de sub-ajuste, en la cual la red no sería capaz de aprender ciertas relaciones existentes entre las variables.

En nuestro caso y por experiencia de modelamiento de sistemas dinámicos complejos, se van a utilizar **16 neuronas en la primera capa oculta y 8 neuronas en la segunda**. La cantidad de neuronas descritas se da debido a que la PC demuestra mejor performance al trabajar con neuronas cuyo número sea potencia de 2.

S1 = 16 neuronas

S2 = 8 neuronas

Retardos o delays

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 datos pasados (ver Figura 4.2). 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.

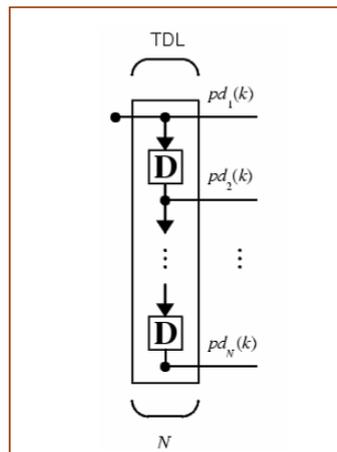


Figura 4.2
Representación de una TDL en tiempo discreto
 Fuente: Matlab Help

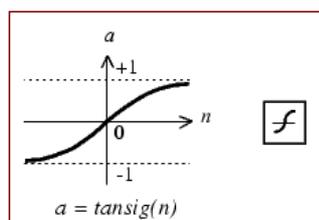
Sin embargo y por capacidad computacional en nuestro se tomarán inicialmente 2 retardos en cada TDL, pudiendo este valor variar de acuerdo a los experimentos y simulaciones posteriormente realizadas.

Funciones de activación

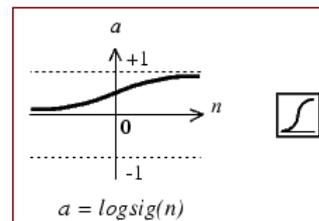
Las principales funciones de activación o funciones de transferencia neuronal, se clasifican en:

- Tansig
- Logsig
- Purelin

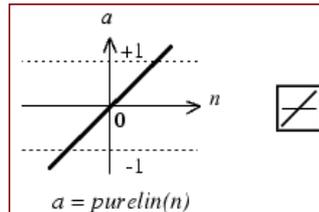
La función Tansig, es una función tangente hiperbólica sigmoidal, cuyo rango está comprendido entre -1 y 1. La función Logsig, es una función logarítmica sigmoidal que con rango entre 0 y 1. La función Purelin, es una función de transferencia lineal donde la entrada es igual a la salida:



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



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



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

Figura 4.3
Principales funciones de activación de las neuronas en una RNA

Fuente: Matlab Help

En nuestro caso hemos elegido funciones ‘tansig’ para las 2 capas ocultas (incluida la capa de entradas), debido a que el incremento se realiza 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.

4.1.2. Diseño de la arquitectura

Las redes neuronales artificiales son sistemas compuestos de elementos simples operando en paralelo. Estos elementos están inspirados en el sistema nervioso biológico. 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 desarrolle una función determinada, ajustando los valores de las conexiones (pesos) entre sus elementos. La Figura 4.4 muestra la estructura general de una RNA.

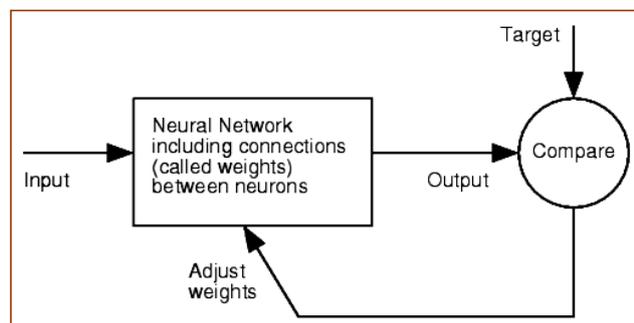


Figura 4.4
Estructura general de una red neuronal
 Fuente: Matlab Help

Las redes neuronales pueden ser clasificadas en las siguientes categorías:

- Redes Estáticas
- Redes Dinámicas

RNA estáticas

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. El entrenamiento de las redes estáticas se realiza a través de los algoritmos de

Backpropagation, que en nuestro caso también se usaron para establecer un patrón inicial de diseño para el módulo de predicción.

El diseño piloto de la RNA estaba basado en este tipo de red, tomando como patrones de entrada sólo valores de calendario, tal como se muestra en la figura 4.5. Sin embargo éste diseño tuvo que ser cambiado, debido a las continuas paradas y fluctuaciones que se dieron en la planta debido a la instalación y plan de pruebas por la modernización.

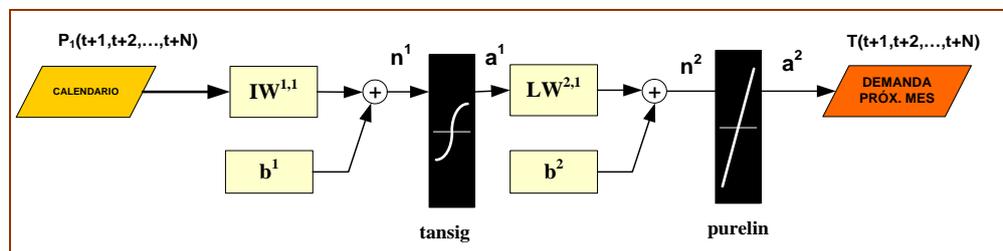


Figura 4.5
Arquitectura de la RNA piloto en formato estándar
(Red Estática Feedforward)
 Fuente y elaboración: Propia

Si se la observa como arreglos de neuronas, se tiene:

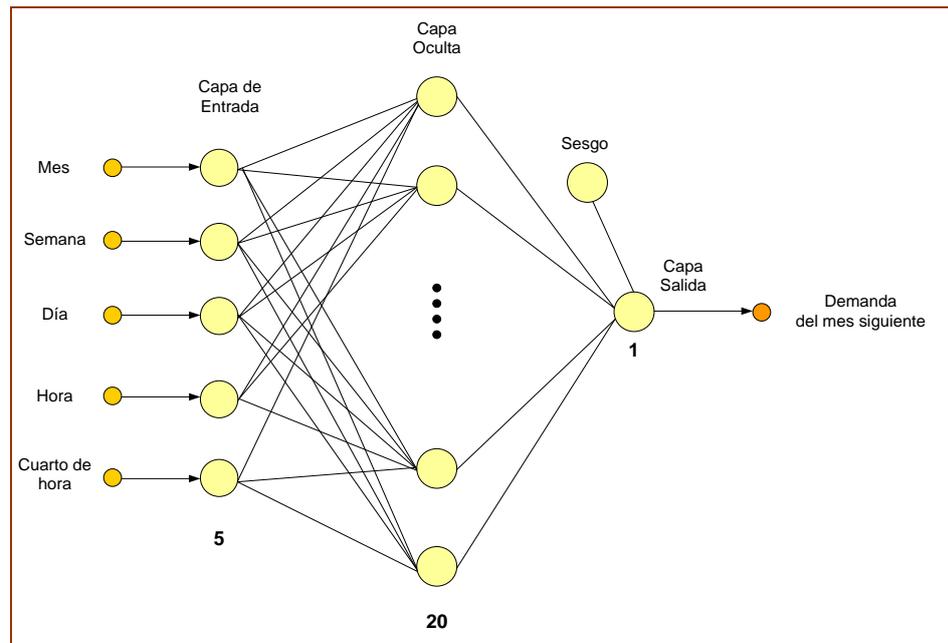


Figura 4.6
Arquitectura de la RNA piloto en formato detallado
 Fuente y elaboración: Propia

RNA dinámicas

En las redes dinámicas, las salidas no sólo 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, tal como se detalló en el capítulo 3.

Las redes dinámicas pueden ser clasificadas en 2 tipos:

- Las que sólo tienen conexiones feedforward.
- Las que presentan realimentación o conexiones recurrentes.

En la Figura 4.7, se observan las principales diferencias entre ambos tipos:

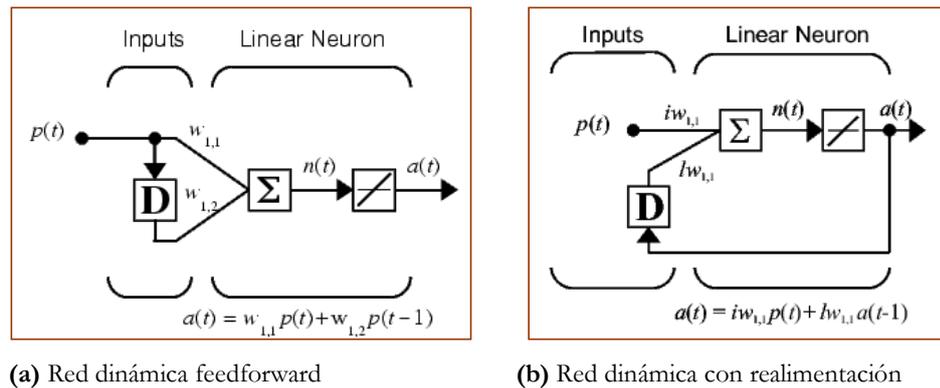


Figura 4.7
Diferencia entre principales redes neuronales dinámicas
 Fuente: Matlab Help

La red dinámica feedforward presenta un delay (retardador) al inicio que simplemente se convierte en una nueva entrada, haciendo dinámico el proceso, pero respecto sólo a las entradas. En la red dinámica con realimentación, en cambio, la salida ya vuelve a la red, convirtiéndose de esta manera en una entrada más pero respecto a lo que se quiere. En nuestro caso las demandas estimadas o predichas, reingresan a la red neuronal, con un retardo predefinido en la programación.

Ventajas de las redes dinámicas

- Las redes dinámicas son generalmente más poderosas que las redes estáticas, en cuanto a predicción y aproximación.
- 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.

Entrenamiento de las redes dinámicas

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 que estas redes pueden ser entrenadas utilizando los mismos algoritmos backpropagation que las redes estáticas, las performances pueden llegar a ser muy diferentes, ya que la gradiente debe ser calculada de una manera más compleja. Considerando la red dinámica simple de la figura 4.7.b, los pesos presentan 2 efectos diferentes en la salida. El primero es el efecto directo, ya que 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 $\mathbf{a}(t-1)$, son además funciones de los pesos.

Redes NARX

Las redes NARX presentan son redes dinámicas recurrentes o realimentadas, las cuales presentan retardos tanto en el vector de entrada como en el de realimentación. Su aplicación es dada principalmente en modelamiento de sistemas dinámicos complejos, muy difíciles para redes

estáticas o redes dinámicas simples, o en el caso de predicción de series largas, como es nuestro caso.

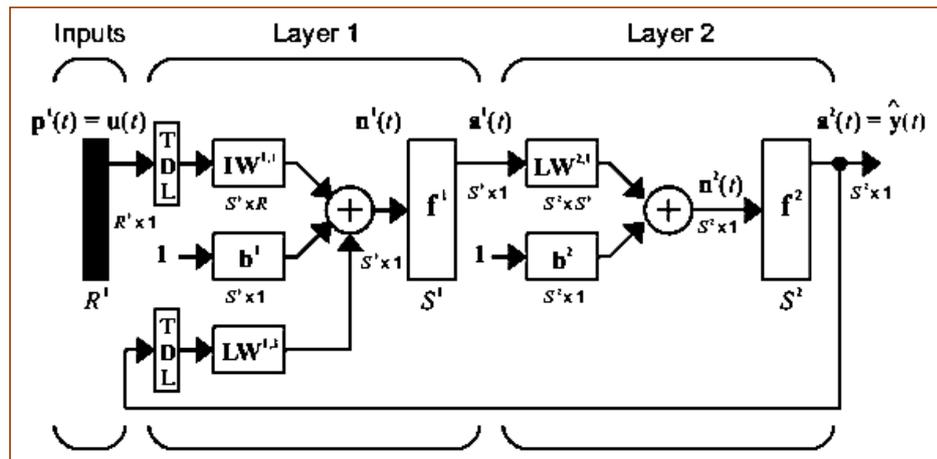


Figura 4.8
Arquitectura de una RNA Dinámica Recurrente NARX simple
Fuente: Matlab Help

Entrenamiento de las redes NARX

El entrenamiento de las redes NARX se da en 2 etapas:

- El entrenamiento con una red de arquitectura serie-paralela, en donde se considera como entrada adicional la data real de salida en ese momento.
- 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 series-paralela.

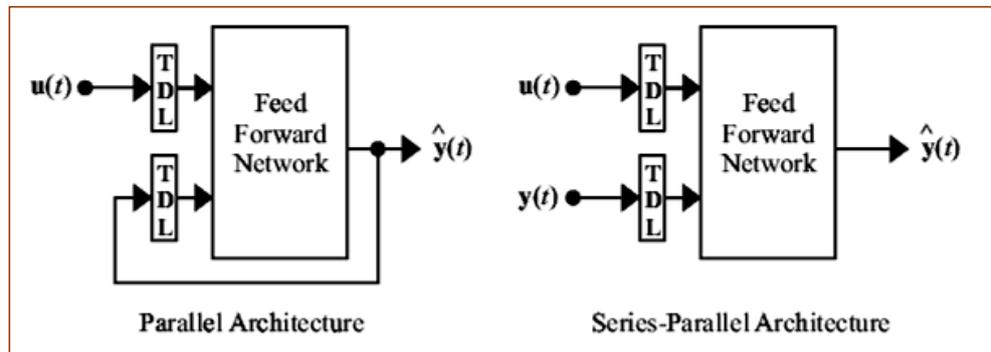


Figura 4.9
Arquitecturas paralela y series-paralela de las redes NARX
 Fuente: Matlab Help

Este procedimiento se da así, para poder realizar una predicción óptima, ya que en el futuro la realimentación se realizará con los valores estimados, de los cuales no se tiene ninguna referencia.

Rediseño de la arquitectura red neuronal

De acuerdo a lo mostrado en los capítulos III y IV, se procedió al diseño de la red neuronal dinámica recurrente (con feedback) NARX modificada.

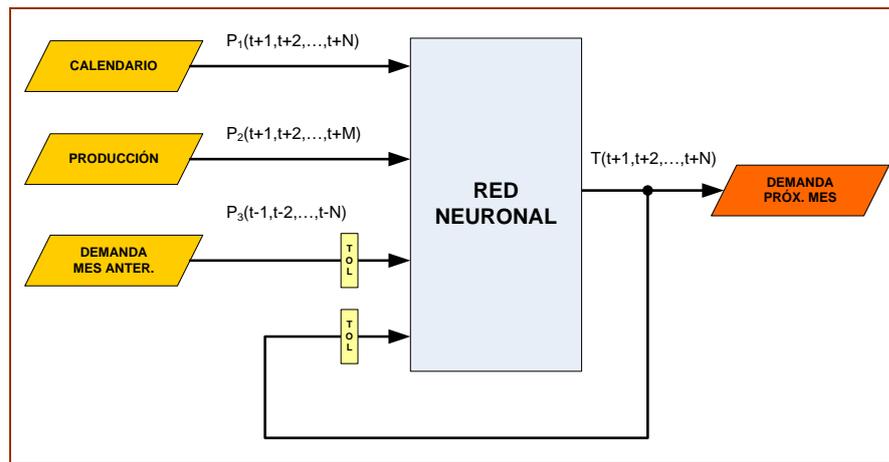


Figura 4.10
Diagrama de bloques de la arquitectura usada en el módulo de predicción
 Fuente y elaboración: Propia

Para este fin y una vez definidos los patrones a utilizar en el acápite 2.2.2, se empezó con la delimitación de la arquitectura en sí.

Arquitectura de la nueva RNA

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

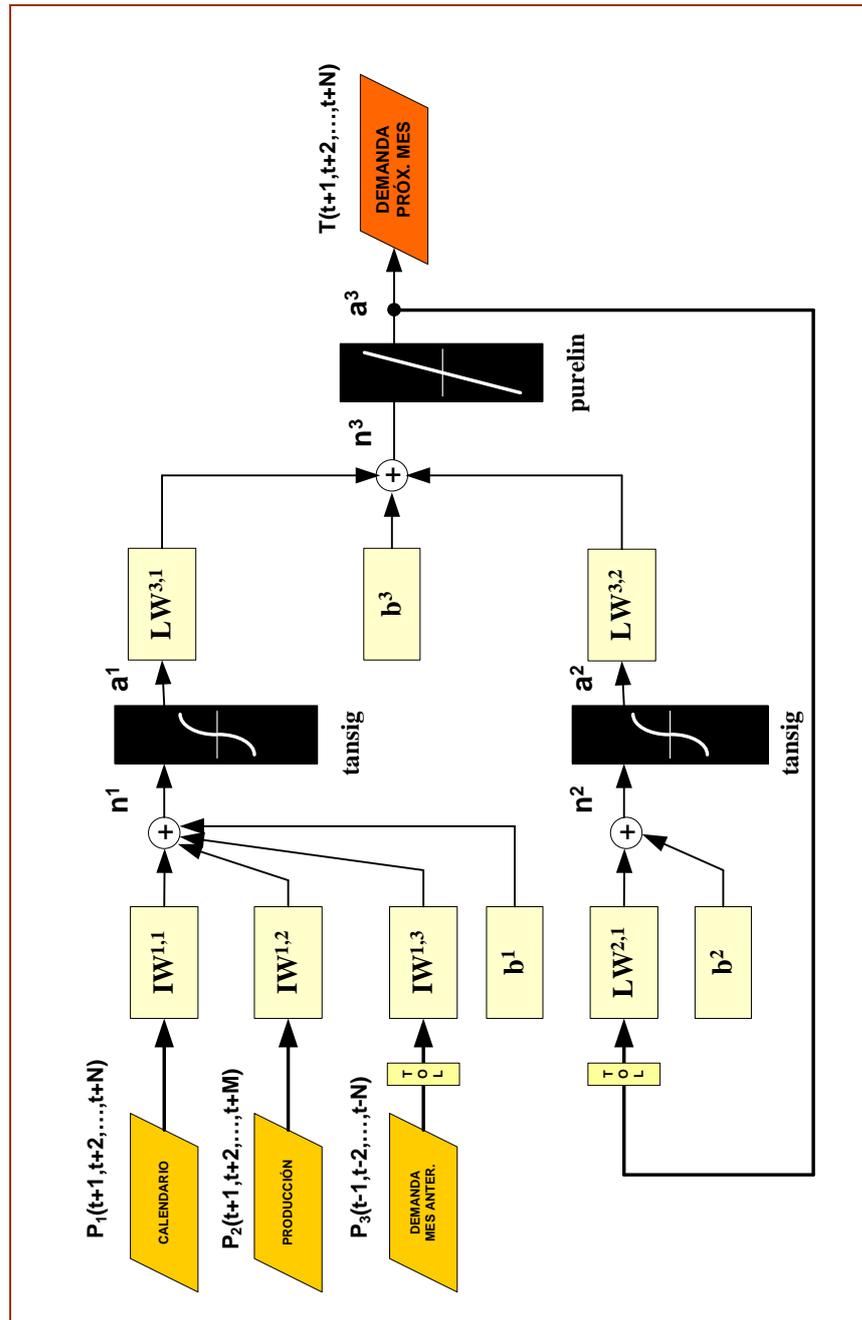


Figura 4.11
Arquitectura final de la RNA
Elaboración: Propia

4.2. CONSTRUCCIÓN

La construcción de la RNA se realizó teniendo en cuenta las limitaciones del software, la capacidad de procesamiento y la cantidad de datos de entrenamiento obtenidos. En los puntos siguientes se mostrará el procedimiento seguido para la construcción de RNA.

4.2.1. Programación

El algoritmo para programar la RNA diseñada en el capítulo 4.1. “Diseño de la Red Neuronal” se muestra en la Figura 4.12.

Como se observa el algoritmo es simple. Existen los pasos de adquisición, filtrado y acondicionamiento de datos; definición, creación y entrenamiento de la RNA; así como, la respectiva validación, la cual se encuentra en un bucle cerrado, hasta que se obtenga el error deseado. Sin embargo, existen muchas consideraciones a tener en cuenta en cada paso. A continuación, se muestra el algoritmo de programación detallado paso a paso, y donde muestran y comentan los posibles problemas que pueden suceder.

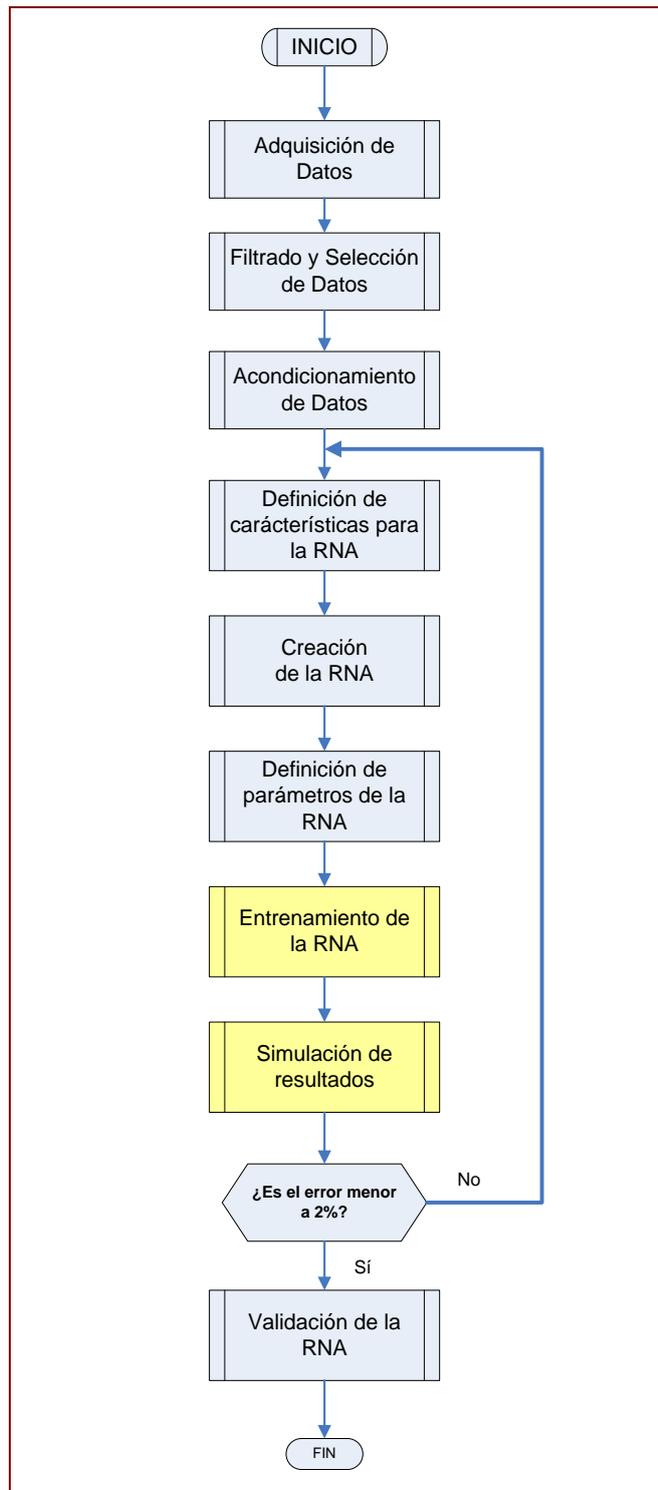


Figura 4.12
Diagrama de flujo de los algoritmos de programación para la RNA
Elaboración: Propia

Adquisición de la data

La adquisición de la data para el entrenamiento, se realizó a partir del archivo 'entrenamiento1.txt', el cual es un arreglo de la data ordenada y clasificada de demanda histórica, producción y calendario. Esta data contiene tanto a los patrones de entrenamiento definidos en el acápite 4.1.1. 'Definición de parámetros', 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 operación presenta un comportamiento estable. La data adquirida está normalizada en el intervalo de [0;1], debido a que presenta una mejor performance en el entrenamiento.

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, definidos en la sección 4.1.1 'Definición de parámetros de la RNA'.
- T : Vector normalizado en el intervalo [0,1] que contiene las demandas de entrenamiento registradas en operación estable.

Filtrado y selección de la data

Para realizar el filtrado de la data, se fijó un umbral equivalente a la media de los datos adquiridos, y se seleccionó aquéllos (patrones y targets) cuya demanda fuese mayor a dicho umbral.

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

Ymax : Demanda máxima registrada en el periodo de toma de datos.

Pn : Patrones filtrados

Tn : Targets filtrados

Acondicionamiento de la data

En el punto anterior, 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 procede al filtrado, se realiza 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
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 : Periodo de aparición de picos de demanda (en cuartos de hora)

Construcción de la Red Narx

En este punto, se crea la RNA NARX, se adecuan las entradas y salidas de entrenamiento en forma de estructuras¹¹ y se definen sus características y parámetros.

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.

¹¹ En el lenguaje de programación Matlab, se define una estructura como una matriz de matrices.

```

%% Creación la Red Narx
% Definición vector de máximos y mínimos
% 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:

- PR1 : Matriz de máximos y mínimos (normalizados) de los patrones de entrada.
- PR2 : 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.

Definición de parámetros de entrenamiento

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 utilice, el costo computacional será mucho mayor, tal y como se explicó en el capítulo III. Entre los más importantes parámetros para el entrenamiento, se tienen: Número de épocas de entrenamiento¹², meta (goal), gradiente mínima, tipo de entrenamiento, número de épocas mostradas.

En este caso, se modificaron 3 parámetros de entrenamiento, dejándose con los valores estándar a los demás. El código utilizado es 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 está probando constantemente, por lo que sólo son referenciales.

¹² Número de veces que se realiza el algoritmo de entrenamiento seleccionado. Cada época de entrenamiento representa un cálculo matricial complicado y extenso, por lo que es necesario un software muy potente para su desarrollo. En este caso el Matlab presenta todas las características de optimización de memoria necesarias para tal fin.

Para los parámetros como meta o gradiente mínima, se utilizan los establecidos por defecto. En el caso de la meta de entrenamiento¹³ (goal), el valor es 0, mientras que para la gradiente mínima, el valor por establecido es 10^{-10} .

Acondicionamiento de entradas y salidas para el entrenamiento

Anteriormente se acondicionó la data, a nivel filtrado y organización; sin embargo, para el entrenamiento se tiene que realizar un arreglo adicional, tal que las entradas y salidas, ya no se presenten 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:

¹³ La meta (goal) está referida al error cuadrático medio (emse), obtenido luego de restar el resultado de la simulación de la red menos la data real.

- 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. Cabe resaltar, que 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

Simulación del entrenamiento

Luego del entrenamiento de la red, se procede a la simulación 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.

Simulación de resultados

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 futuros definidos en el capítulo 4.1.1 y 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
    Pil = PTi(:,1:4);
    Til = PTi(:,5) + offset;
    set(handles.text23,'String','Agosto 2007');
case 2
    offset = 0.011; % factor de incremento de producción
    Pil = PTi(:,6:9);
    Til = PTi(:,10) + offset;
    set(handles.text23,'String','Setiembre 2007');
case 3
    offset = 0.013; % factor de incremento de producción
    Pil = PTi(:,11:14);
    Til = PTi(:,15) + offset;
    set(handles.text23,'String','Octubre 2007');
end

% Filtrado de la data
mi = mean(Til); % media de la data
si = std(Til); % desviación estándar
p = 19; % periodo de picos (en cuartos de hora)

% Filtramos de la data futura
for i = 1:length(Til)
    if Ymax*Til(i) < 37000
        Til(i) = 1.05*(mi+0.003*mi*rand(1)) + 0.1*si*rand(1);
        if (i-floor(i/p)*p) == 0
            Til(i) = 1.005*Til(i);
            Til(i-1) = 1.01*Til(i);
            Til(i-2) = 1.04*Til(i);
            Til(i-3) = 1.04*Til(i);
            Til(i-4) = 1.01*Til(i);
            Til(i-5) = 1.005*Til(i);
        end
    end
end
end

Pci = con2seq(Pil');
Tci = con2seq(Til');

```

```

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

Simulación de la predicción

Una vez acondicionados los patrones futuros de la RNA, se procedió a la simulación para obtener la data 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:

- y_{pi} : Estructura normalizada de salida de la RNA con los patrones de predicción.
- y_i : Vector de demanda simulada con los patrones de predicción.
- n_i : Número de muestras de 'y'.
- T_{fi} : Vector de demanda real utilizada en la predicción.
- e_i : Vector de error de predicción.
- e_{pi} : Vector de porcentaje de error por punto para la predicción.
- $emsei$: Error cuadrático medio de predicción.

4.2.2. Entrenamiento de la red

Las redes dinámicas presentan mejores resultados de entrenamiento y simulación para el problema de predicción que las redes estáticas. Los criterios para la elección de los parámetros óptimos son diversos; sin embargo, debido a la diversidad de sistemas dinámicos y de predicción, no existe un criterio unificado. Por tal motivo se utilizará el criterio de prueba y error, modificando los parámetros dentro de rangos normales y recomendados¹⁴.

En el caso de la predicción de la demanda eléctrica, los parámetros a modificar son el número de capas, número de neuronas, número de delays y

¹⁴ Revisar el capítulo III

tipo de funciones de activación. El número de épocas de entrenamiento, permanecerá constante¹⁵ mientras se eligen los parámetros.

Las redes dinámicas son entrenadas usando los mismos algoritmos basados en gradiente que se usan en las redes estáticas (Backpropagation).

A pesar que las redes dinámicas pueden ser entrenadas usando los mismos algoritmos para redes estáticas, la performance de los algoritmos en las redes dinámicas puede ser muy diferente, debido a que la gradiente debe ser calculada de una manera más compleja. Si se considera una red recurrente simple, vemos que presenta 2 efectos diferentes en su salida. El primero es el efecto directo, ya que un cambio en los pesos causa un cambio inmediato en la salida del tiempo actual. (Este primer efecto puede ser calculado usando el algoritmo estándar backpropagation). El segundo, es un efecto indirecto, debido a que algunas de las entradas de la red, son funciones de los pesos. Para calcular este efecto indirecto, se deben usar algoritmos backpropagation dinámicos, lo cual presenta un costo computacional mucho más alto.

Además los algoritmos backpropagation dinámicos toman más tiempo para el entrenamiento. Otro punto adicional, es el cálculo de los errores que es mucho más complejo. Esto sugiere que se necesita entrenar muchas veces antes de obtener un resultado óptimo.

De acuerdo al algoritmo de entrenamiento de la RNA, establecido a la sección anterior 4.2, 'Programación de la RNA', se procedió a modificar los siguientes parámetros de la RNA NARX, de tal manera que se pueda

¹⁵ El número de épocas utilizado es 50. En el módulo de predicción propiamente este valor será estándar, sin embargo existirá la posibilidad de entrenar nuevamente la red, añadiéndole 50 épocas más por cada vez que se le solicite.

observar su performance y error de entrenamiento. Los parámetros modificados son los siguientes:

- Número de capas
- Número de neuronas por capa
- Número de delays
- Funciones de activación

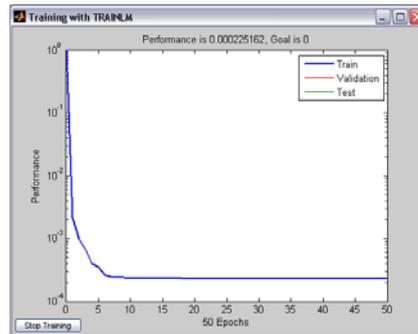
Tabla 4.1
Parámetros a modificar en el entrenamiento

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

Elaboración: Propia

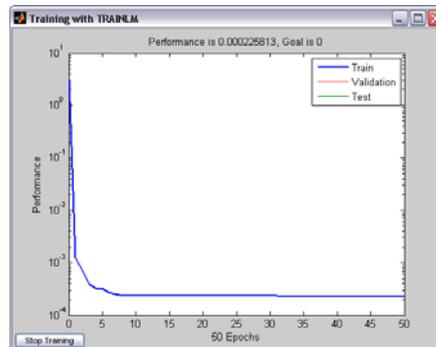
El número de épocas se considerará constante e igual a 50, debido a que en todas las performances de entrenamiento, el error cuadrático medio se estabiliza entre las épocas 20 y 30. El error puede disminuir si se aumentan el número de épocas a 100 o 200; sin embargo, esto no sería recomendable, ya que se puede producir un sobre-entrenamiento, el cual resultaría muy perjudicial en predicción.

A continuación se muestran los resultados de los distintos entrenamientos, así como sus respectivos errores:



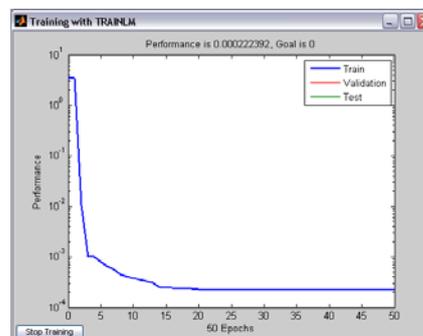
S1	S2	d	FA1	FA2	mse
16	8	2	tansig	tansig	0.2769 %

(a) Curva de entrenamiento con 2 capas de neuronas, 2 delays y funciones de activación 'tansig'. **Herramienta:** Matlab



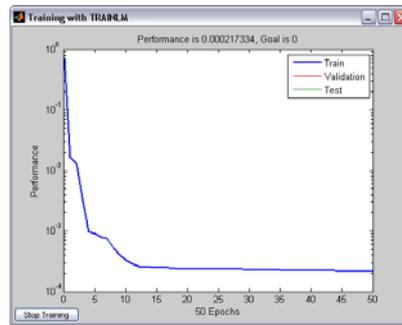
S1	S2	d	FA1	FA2	mse
10	0	2	tansig	-	0.3392 %

(b) Curva de entrenamiento con 1 capas de neuronas, 2 delays y función de activación 'tansig'. **Herramienta:** Matlab



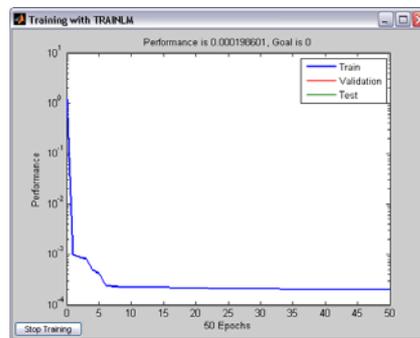
S1	S2	d	FA1	FA2	mse
10	5	2	tansig	tansig	0.3916 %

(c) Curva de entrenamiento con 2 capas de neuronas, 2 delays y funciones de activación 'tansig'. **Herramienta:** Matlab



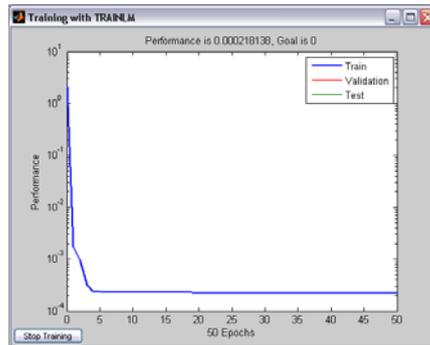
S1	S2	d	FA1	FA2	mse
10	5	4	tansig	tansig	0.4535 %

(d) Curva de entrenamiento con 2 capas de neuronas, 4 delays y funciones de activación 'tansig'. **Herramienta:** Matlab



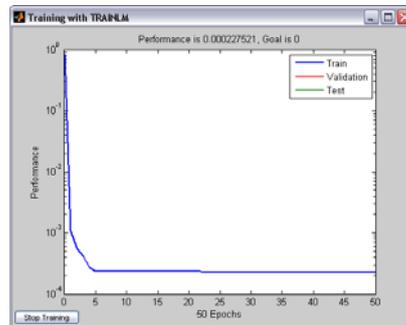
S1	S2	d	FA1	FA2	mse
10	5	6	tansig	tansig	0.6595 %

(e) Curva de entrenamiento con 2 capas de neuronas, 6 delays y funciones de activación 'tansig'. **Herramienta:** Matlab



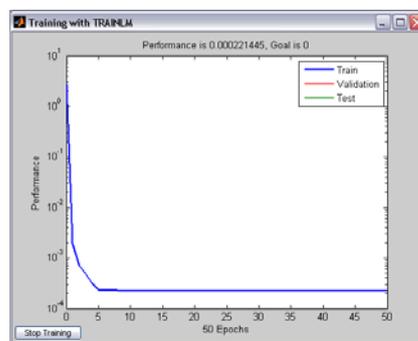
S1	S2	d	FA1	FA2	mse
10	0	6	logsig	-	0.3915 %

(f) Curva de entrenamiento con 1 capas de neuronas, 6 delays y funciones de activación 'logsig'. Herramienta: Matlab



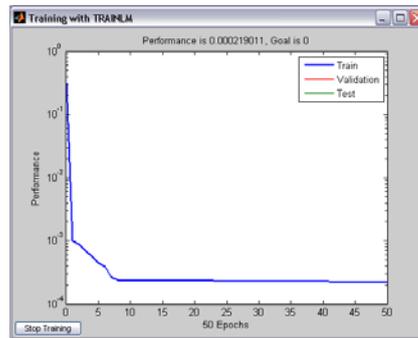
S1	S2	d	FA1	FA2	mse
10	0	2	logsig	-	0.3141 %

(g) Curva de entrenamiento con 1 capas de neuronas, 2 delays y funciones de activación 'logsig'. Herramienta: Matlab



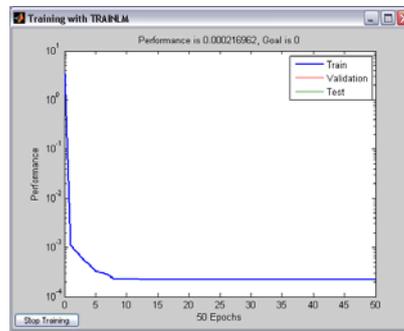
S1	S2	d	FA1	FA2	mse
20	0	2	logsig	-	0.3528 %

(h) Curva de entrenamiento con 1 capas de neuronas, 2 delays y funciones de activación 'logsig'. Herramienta: Matlab



S1	S2	d	FA1	FA2	mse
8	0	2	logsig	-	0.4229 %

(i) Curva de entrenamiento con 1 capas de neuronas, 2 delays y funciones de activación 'logsig'. **Herramienta:** Matlab



S1	S2	d	FA1	FA2	mse
10	5	2	logsig	logsig	0.4399 %

(j) Curva de entrenamiento con 2 capas de neuronas, 2 delays y funciones de activación 'logsig'. **Herramienta:** Matlab

Figura 4.13
Curvas de entrenamiento

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

Tabla 4.2
Curvas de 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 %

Elaboración: Propia

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 en el acápite 4.1.1, vemos que se obtiene una mejor performance en entrenamiento.

El resultado obtenido de entrenamiento, es el siguiente:

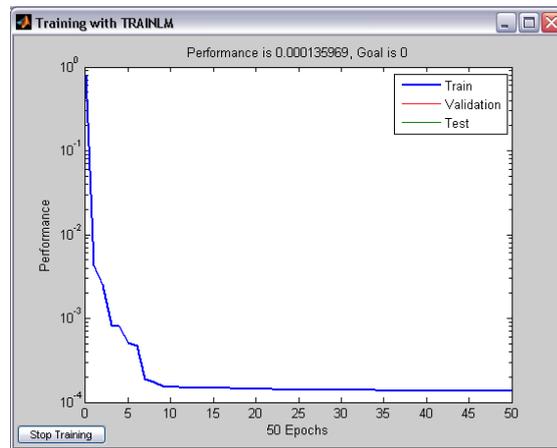


Figura 4.14
Entrenamiento de la RNA NARX con los parámetros óptimos
 Elaboración: Propia

Al modificar los parámetros de entrenamiento para la red neuronal NARX, no se observa gran variación entre los resultados obtenidos para el error cuadrático medio, cuyos valores oscilan entre 0.28% y 0.65%. Por lo tanto la elección de parámetros se realizó teniendo como criterios el mínimo error y el mínimo costo computacional.

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.

4.2.3. Interfaz gráfica

Características principales

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 (periodo 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 diseñada en la sección 4.1 y programada en la sección 4.2. 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 el capítulo II. Esta función extrae, una vez obtenida la demanda, los cargos por energía y potencia, base y

adicional, disgregados, así como el valor o pago final de la Fundición 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):

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

4.1

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 selecciona Blank GUI (Default), tal como se muestra en el Figura 4.15.

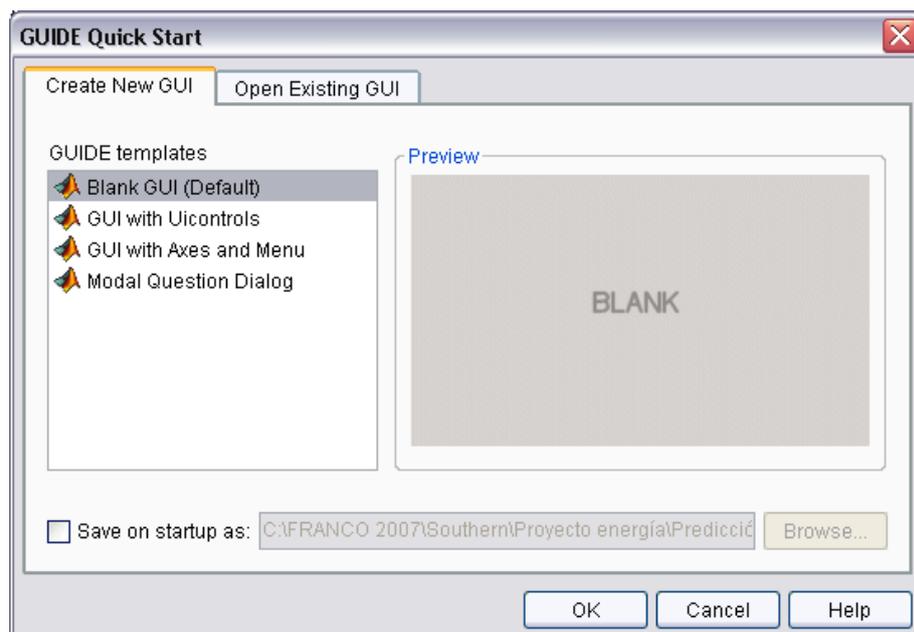


Figura 4.15
Ventana inicial de la herramienta GUIDE de Matlab
 Fuente: Matlab

Una vez con la ventana de diseño abierta, se procede a elaborar la pantalla de trabajo, colocando y ordenando los objetos necesarios, tal como se muestra en la figura 4.16.

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 Buttom1) 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 (Static text) para los datos relevantes, tales como energía consumida en el mes, demanda máxima y cargos o pagos.

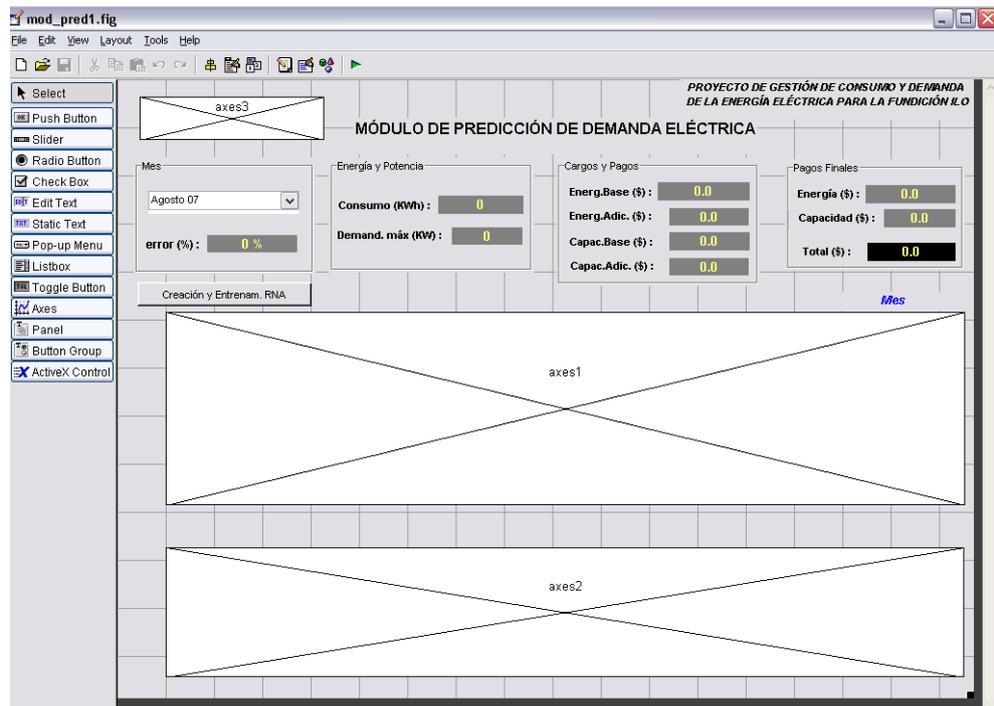


Figura 4.16
Pantalla de diseño de la interfaz gráfica
 Elaboración: Propia. Herramienta: Matlab

Programación de la interfaz

Una vez diseñada la interfaz gráfica, se programan los objetos individualmente y se procede a realizar los enlaces entre ellos.

En la Figura 4.17, 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.

```

Editor - C:\FRANCO 2007\Southern\Proyecto energia\Predicción\Programación\mod_pred1.m
File Edit Text Go Cell Tools Debug Desktop Window Help
Stack: Base
- 1.0 + ÷ 1.1 x % % % % %
1 %% MODULO DE PREDICCIÓN DE DEMANDA ELÉCTRICA
2 %% PROYECTO DE GESTIÓN DE DEMANDA Y CONSUMO DE LA ENERGÍA ELÉCTRICA
3 %% PARA LA FUNDICIÓN ILO
4
5 function varargout = mod_pred1(varargin)
6 % MOD_PRED1 M-file for mod_pred1.fig
7 %   MOD_PRED1, by itself, creates a new MOD_PRED1 or raises the existing
8 %   singleton*.
9 %
10 %   H = MOD_PRED1 returns the handle to a new MOD_PRED1 or the handle to
11 %   the existing singleton*.
12 %
13 %   MOD_PRED1('CALLBACK',hObject,eventData,handles,...) calls the local
14 %   function named CALLBACK in MOD_PRED1.M with the given input arguments.
15 %
16 %   MOD_PRED1('Property','Value',...) creates a new MOD_PRED1 or raises the
17 %   existing singleton*. Starting from the left, property value pairs are
18 %   applied to the GUI before mod_pred1_OpeningFunction gets called. An
19 %   unrecognized property name or invalid value makes property application
20 %   stop. All inputs are passed to mod_pred1_OpeningFcn via varargin.
21 %
22 % *See GUI Options on GUIDE's Tools menu. Choose "GUI allows only one
23 %   instance to run (singleton)".
24 %
25 % See also: GUIDE, GUIDATA, GUIHANDLES
26
27 % Edit the above text to modify the response to help mod_pred1
28
29 % Last Modified by GUIDE v2.5 07-Aug-2007 11:18:23
30
31 % Begin initialization code - DO NOT EDIT
32 end % Singleton

```

Figura 4.17
Pantalla de programación de la interfaz gráfica
 Elaboración: Propia. Herramienta: Matlab

Con la interfaz programada y con los algoritmos de creación, entrenamiento y simulación de la red neuronal añadidos, procedemos a correr, el módulo de predicción, presionando el botón Run, tal como se muestra en la Figura 4.18.

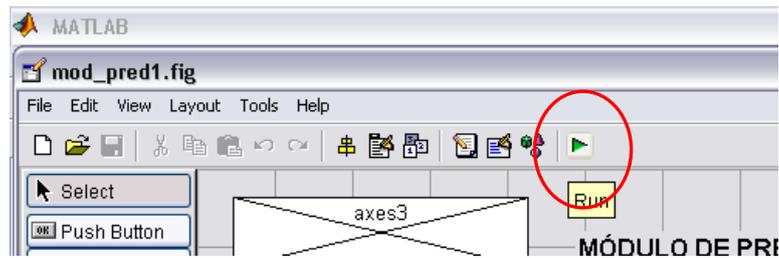


Figura 4.18
Pantalla para correr el módulo de predicción
 Elaboración: Propia. Herramienta: Matlab

Otra forma de correr el módulo es escribiendo el nombre del archivo, en el escritorio de Matlab¹⁶:

```
>> mod_pred1
```

En la Figura 4.19, se muestra la pantalla inicial de trabajo del módulo de predicción de demanda eléctrica:

¹⁶ No se debe olvidar ubicar correctamente la ruta de la carpeta de trabajo donde se han guardado los archivos .m y de entrenamiento.

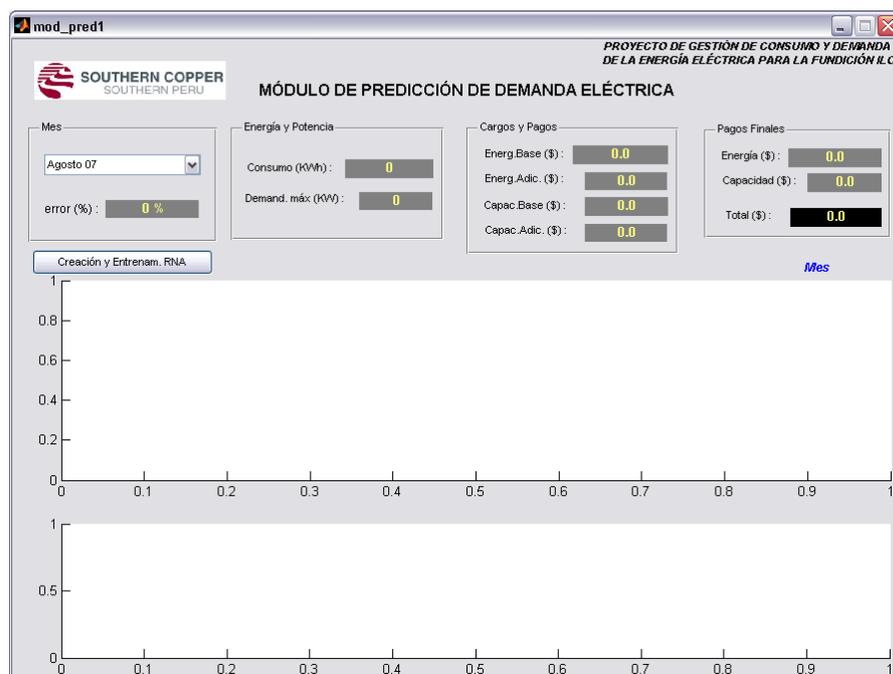


Figura 4.19
Pantalla inicial del módulo de predicción
 Elaboración: Propia. Herramienta: Matlab

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’**.



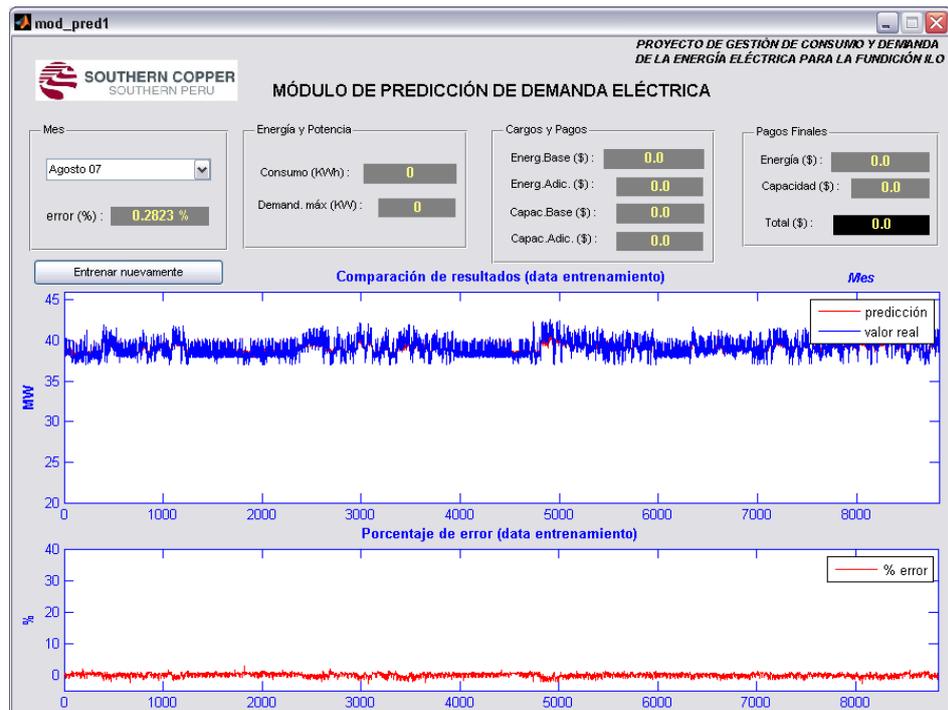


Figura 4.20
Pantalla del módulo de predicción luego del entrenamiento
 Elaboración: Propia. Herramienta: Matlab

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



4.3. VALIDACIÓN

4.3.1. Plan de pruebas

La metodología para realizar las pruebas, se realizó considerando la disponibilidad de las fuentes, la facilidad de su acceso y la capacidad de manejo de bases de datos. En el caso del servidor IION, se almacenan los datos de demanda validados por el área de Sistemas de Potencia; sin embargo, su capacidad de almacenamiento es limitada, por lo que se tomará la data diariamente. En el caso del servidor Wonderware, se tiene un manejo de datos mucho más versátil, ya que trabaja con bases de datos SQL, por lo que la toma de datos puede realizarse en cualquier momento; sin embargo, esta data es tomada con medidores propios de SPCC, que no son considerados en la facturación final, por lo que se le tiene que validar con los reportes mensuales de Sistemas de Potencia, que trabajan con un medidor diferente, el cual es compartido con Enersur. La metodología es la siguiente:

- Cargar la data del servidor IION, diariamente a la base de datos del módulo 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 entre agosto y septiembre.

La predicción y la validación se realizarán en las fechas donde ya se cuente con la cantidad de data adecuada y verificada.

Las fechas para la toma de datos y las predicciones, se encuentran en la Tabla 4.3.

Tabla 4.3
Cronograma de toma de datos para la validación

Fecha	Servidor IION	Servidor Wonderware (A.Factory)	Reportes Sistemas 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			
26-Sep	X				
27-Sep	X				
28-Sep	X				
29-Sep	X				
30-Sep	X	X		X	

4.3.2. Contrastación de resultados

De acuerdo al cronograma presentado en el acápite anterior, para realizar la validación del módulo de predicción, se llevo a cabo la predicción de la demanda eléctrica para el mes de octubre del 2007.

En la Figura 4.21 se muestra el comportamiento de la demanda predicha para el mes de octubre 2007.

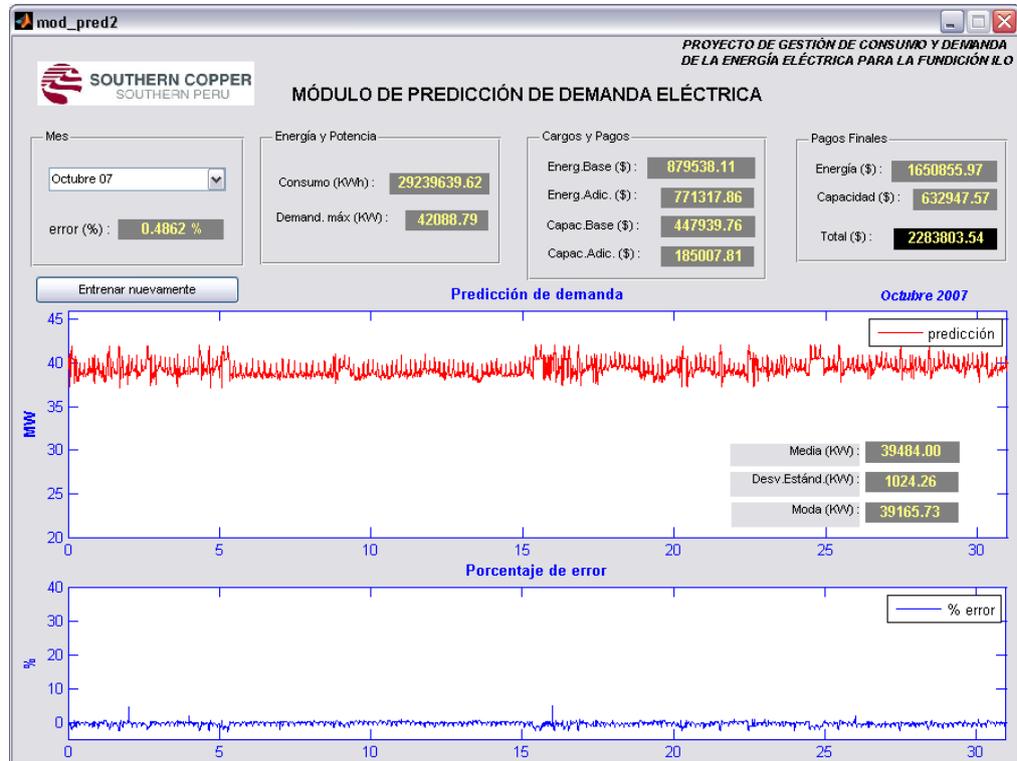


Figura 4.21
Demanda predicha Octubre 2007

La data obtenida para la validación es la data oficial del servidor IION, y que consta en los reportes del departamento de Sistemas de Potencia.

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

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

4.2

Donde:

- p_i : Dato simulado
 r_i : Dato real
 N : Número de muestras

La Tabla 4.4 muestra el error cuadrático medio de toda la serie de datos, obtenida de acuerdo a la ecuación 4.2.

Tabla 4.4
Error cuadrático medio

Mes	%erms
Oct-07	0.4862%

Se debe tener en cuenta, que este error se ha tomado considerando una producción constante y que no han existido caídas o paradas en las plantas.

Por tal motivo, en las Tablas 4.5 y 4.6 se muestra el error de energía y demanda total del módulo de predicción, en la cual sí existieron paradas o caídas de planta.

Tabla 4.5
Validación en consumo eléctrico total (total mensual)

Mes	$E_{predicha}$ (KWh)	E_{real} (KWh)	%error
Oct-07	29,239,640	28,336,177	3.09%

Tabla 4.6
Validación en demanda eléctrica total (máximo mensual)

Mes	$D_{predicha}$ (KW)	D_{real} (KW)	%error
Oct-07	42,089	42,569	-1.14%

4.3.3. Monitoreo

Una vez validado el módulo predictor, el monitoreo es el paso final para el control de la demanda eléctrica en una planta industrial. Para este fin, se puede seguir el plan previamente desarrollado, de tal manera que se tenga un margen de error relativamente confiable y que permita tomar las decisiones adecuadas y la planificación adecuadas, de acuerdo a la evolución del consumo y sus costos correspondientes.

CAPÍTULO 5

MÓDULO DE SIMULACIÓN

El funcionamiento de los procesos industriales ha cambiado drásticamente en las últimas décadas. Este cambio se da principalmente debido a la evolución de la tecnología de las computadoras. La automatización de los procesos ha provocado un aumento de la productividad de algunos sectores industriales, obligando a la industria a adaptarse a las demandas de mercado y aumentar su competitividad (Backx, 1993).

Para aumentar la competitividad ha sido necesario desarrollar nuevas técnicas: métodos y herramientas que permitan maximizar la eficiencia de los procesos, desarrollando controladores de gran calidad, y maximizar la flexibilidad de los procesos con el menor ajuste de la maquina. Para ello es imprescindible conocer el comportamiento dinámico del proceso, principalmente de las partes críticas.

5.1. FUNDAMENTOS

En la actualidad, cada vez más, el trabajo de un ingeniero consiste en la realización de modelos matemáticos de los procesos estudiados (Ljung, 1994). Los modelos son utilizados en áreas tan distintas como: bioingeniería, construcción, economía, meteorología, procesos químicos, etc. El campo de utilización de dichos

modelos es muy amplio, caben destacar aplicaciones como: control, supervisión, predicción, simulación, optimización, etc.

Según Seborg (1996), las estrategias actuales de diseño de controladores pueden clasificarse en dos grupos: control convencional y control avanzado. El control convencional consistente en el control: manual, PID, de relación, en cascada, en avance o retardo de fase. Según dicho autor el 90% de los controladores de procesos industriales son actualmente controladores convencionales. Las estrategias de control avanzado se subdividen en tres grupos: técnicas de control convencionales (control desacoplado, control selectivo, control con compensación de retardo puro), técnicas de control basadas en modelos numéricos (control predictivo, control adaptativo, control robusto, control con modelo interno) y técnicas de control basadas en conocimiento (sistemas expertos, control neuronal, control fuzzy). Tanto para la utilización de técnicas de diseño convencionales como técnicas avanzadas y especialmente las basadas en modelos, es necesario un modelo numérico preciso del proceso estudiado.

Cabe comentar también, que los procesos industriales están sujetos a severos requerimientos de eficacia, disponibilidad y seguridad. La complejidad de los mismos crece constantemente y esto hace necesario el desarrollo de herramientas automáticas de ayuda al operador humano: los sistemas de supervisión.

Entre las tareas de este tipo es necesario destacar las tareas destinadas a la detección y diagnóstico de fallos. Con una rápida detección de los fallos se puede evitar desde una pérdida de prestaciones hasta un deterioro del sistema con consecuencias que pueden ser catastróficas para el propio sistema e incluso para el personal de la planta. Los sistemas de detección de fallos se basan en la obtención de

síntomas, de señales indicadoras de fallos, y su análisis para indicar la posible existencia y localización de dicho fallo. Uno de los métodos utilizados para ello es la comparación del proceso con un modelo de simulación, son los métodos denominados diagnóstico basado en modelos como en Iserman (1984) y Gertler (1998).

Principalmente, por las dos razones expuestas anteriormente: diseño de controladores y métodos de detección de fallos, es necesario disponer de un modelo matemático que se ajuste al comportamiento del sistema eléctrico a optimizar.

5.2. ESTRUCTURA Y CLASIFICACIÓN DE MODELOS

5.2.1. Aspectos generales

Se denomina **identificación** a la técnica de construir un modelo a partir de las variables medidas del proceso: entradas o variables de control, salidas o variables controladas y, posiblemente, perturbaciones. En principio y con el objetivo de modelizar se pueden proponer tres formas distintas de utilizar los métodos de identificación:

- Hacer distintas aproximaciones para estructurar el problema: seleccionar las señales de interés, observar la dependencia entre ellas, estudiar el grado de linealidad del proceso.
- Construir un modelo que describa el comportamiento entre las entradas y las salidas, prescindiendo del comportamiento físico. Hay

distintas formas de abordar el problema, según se consideren **modelos no paramétricos** o **modelos paramétricos**.

- Utilizar los datos para determinar los parámetros no conocidos del modelo físico obtenido a base del estudio de propiedades y leyes físicas del proceso estudiado. En este caso se habla de modelos “**tailor-made**” de los cuales se debe estimar solamente los valores de los parámetros no conocidos. Para ello se recurre a ensayos de comportamiento o pruebas físicas y/o a la utilización de técnicas de optimización.

Esta modelización se basa en las dos primeras

Otro aspecto a tener en cuenta será el tipo de modelo matemático que se pretende identificar. Hay varias formas de catalogar los modelos matemáticos (Ljung, 1994): deterministas o estocásticos, dinámicos o estáticos, de parámetros distribuidos o concentrados, lineales o no lineales, y de tiempo continuo o tiempo discreto. Los tipos de modelos que se utilizarán en esta tesis serán:

- **Deterministas**, ya que se quiere estudiar la relación entre la entrada y la salida con una parte no modelizable o no conocida (estocástica);
- **Dinámicos**, porque el objetivo es conocer el comportamiento dinámico de un proceso;
- **De parámetros concentrados**, no se considera la variación en función del espacio;

- **Lineales o no lineales**, se hará mayor énfasis a las técnicas de identificación de modelos lineales, comentado algunas técnicas para ser utilizadas en el caso de sistemas no lineales;
- **Tiempo continuo o tiempo discreto**, se propone describir técnicas para la identificación de modelos en tiempo discreto y continuo.

Se deben dejar claros varios aspectos en cuanto a la construcción de un modelo:

- Un modelo se desarrolla siempre a partir de una serie de aproximaciones e hipótesis y, por lo tanto, es una representación parcial de la realidad;
- Un modelo se construye para una finalidad específica y debe ser formulado para que sea útil a dicho fin;
- Un modelo tiene que ser por necesidad un compromiso entre la simplicidad y la necesidad de recoger los aspectos esenciales del sistema en estudio.

5.2.2. Estructura del modelo

Partiendo de la base de que para modelizar un proceso necesitamos los datos observados, en el caso de un sistema dinámico con una entrada en el instante t denominada como $u(t)$ y una salida en el instante t denominada como $y(t)$ los datos serán una colección finita de observaciones:

$$Z^N = \{u(0), y(0), u(1), y(1), \dots, u(N), y(N)\} \quad 5.1$$

El problema de los métodos de identificación consiste en encontrar relaciones matemáticas entre las secuencias de entrada y las secuencias de salida. O también, si definimos las observaciones de forma más general:

$$Z^N = \{[y(t), \varphi(t)]\}; \quad t = 1, \dots, N \quad 5.2$$

lo que preocupa es como determinar $y(N+1)$ a partir de $\varphi(N+1)$. En el caso de un sistema dinámico, $\varphi(t)$ contendría la información de las entradas y salidas anteriores a t .

El problema matemático que se formula es la construcción de una función $\hat{g}_N(t, \varphi(t))$ tal que a partir de ella se puede determinar $y(t)$:

$$\hat{y}(t) = \hat{g}_N(t, \varphi(t)) \quad 5.3$$

En general se busca una función g que sea parametrizable, es decir que tenga un número finito de parámetros. A estos parámetros se les denomina con θ . A toda la familia funciones candidatas se las denomina **estructura del modelo**, y en general estas funciones se escriben como $g_N(t, \theta, \varphi(t))$. Esta función permite calcular el valor $y(t)$:

$$y(t) \approx g_N(t, \theta, \varphi(t)) \quad 5.4$$

La búsqueda de una buena función se realiza en términos del parámetro θ , y el cálculo del valor $\hat{\theta}_N$ conduce a:

$$\hat{g}_N(t, \varphi(t)) = g_N(t, \hat{\theta}, \varphi(t)) \quad 5.5$$

Por ejemplo en el caso de una estructura de modelo simple como ARX de primer orden:

$$y(t) + ay(t-1) = b_1u(t-1) + b_2u(t-2) \quad 5.6$$

la correspondencia con la formulación general sería:

$$\begin{aligned} \theta &= (a, b_1, b_2) \\ \varphi(t) &= (y(t-1), u(t-1), u(t-2)) \\ g(t, \theta, \varphi(t)) &= -ay(t-1) + b_1u(t-1) + b_2u(t-2) \end{aligned} \quad 5.7$$

El ejemplo anterior muestra la formulación convencional de los sistemas de identificación, en que la estructura del modelo se corresponde con una regresión lineal. En general, la estructura del modelo podría ser cualquiera, desde regresiones no lineales (caso en que g es no lineal respecto a θ), modelos tipo **taylor-made**, a redes neuronales. También podrían incluirse modelos dinámicos **Fuzzy** en el caso en que se reemplazara $\varphi(t)$ y

$y(t)$ por valores como “el horno está muy caliente”, “el horno está tibio”, “el agua está hirviendo”, etc.

5.2.3. Modelos paramétricos

La utilización de modelos como $g_N(t, \theta, \varphi(t))$ indica que se está restringiendo a un conjunto pequeño de modelos parametrizados respecto a θ . Un caso interesante es cuando se asume que la correcta representación del sistema pertenece a un gran número de sistemas y que no pueden parametrizarse con un número finito de parámetros. Un ejemplo sería el de la respuesta impulso en donde su modelo corresponde a un número infinito de coeficientes. Matemáticamente este concepto se representa por:

$$\bigcup_{d=1}^{\infty} g_d(t, \theta^d, \varphi(t)) \quad 5.8$$

en donde el vector θ^d contiene d parámetros. Por supuesto que para cada conjunto finito de datos Z^N se tiene un $d < \infty$. Esta situación se denomina no paramétrica. Los modelos no paramétricos se presentan en el acápite 5.3.

5.2.4. Clasificación de los métodos de identificación paramétrica

1. Principio de identificación de sistemas

Como se ha comentado en el apartado anterior, el principio de la identificación de sistemas dinámicos se basa en buscar $g(t, \theta, \varphi(t))$ de manera que:

$$y(t) \text{ próximo a } g(t, \theta, \varphi(t))$$

Este principio también incluye el caso en donde φ y y son valores no numéricos, en el caso en que “próximo” se defina adecuadamente. Si consideramos el caso numérico se debe seleccionar $\theta = \hat{\theta}_N$ tal que:

$$V_N(\theta) = \frac{1}{N} \sum_{t=1}^N \|y(t) - g(t, \theta, \varphi(t))\| \quad 5.9$$

se minimiza considerando alguna norma $\|\cdot\|$, por ejemplo: $\|\varepsilon\| = |\varepsilon|^2$, siendo:

$$\varepsilon(t, \theta) = y(t) - g(t, \theta, \varphi(t)) \quad 5.10$$

Este caso origina una familia de métodos de identificación denominados “métodos de predicción del error”.

2. Clasificación de los métodos de identificación

Son varios los criterios a partir de los cuales clasificar los métodos de identificación (Iserman, 1980). Se pueden considerar en primer lugar unos aspectos prácticos:

- a) error entre proceso y modelo;
- b) algoritmo utilizado;
- c) secuencia de evaluación o procesada de las medidas.

a) Evaluando el error entre el modelo y el proceso se puede diferenciar entre **ecuación de error y error en la señal de salida**. El primero se suele utilizar cuando se dispone de un modelo con una función de pesos, y la segunda si se dispone de una función de ecuaciones diferenciales y/o funciones de transferencia. Para ilustrar la diferencia entre ambas aproximaciones consideremos las siguientes estructuras de modelo:

$$\text{- estructura ARX: } y(t) + ay(t-1) = b_1u(t-1) + b_2u(t-2) + v(t) \quad 5.11$$

$$\text{- estructura OE: } y(t) = \frac{b_1 + b_2q^{-1}}{1 + f_1q^{-1}} u(t-1) + v(t) \quad 5.12$$

donde $y(t)$ es la medida de la salida del sistema, $u(t)$ es la medida de la entrada del sistema mientras que $v(t)$ es el término perturbación (ruido, señal no conocida). Dependiendo de la estructura del modelo, la estimación de la señal error será:

- **Ecuación del error**, estructura ARX, calculado por la expresión:

$$\varepsilon(t) = y(t) + a_1 y(t-1) + b_1 u(t-1) + b_2 u(t-2) \approx v(t) \quad 5.13$$

donde tanto el histórico de las entradas como salidas influyen en el cálculo del término error.

- **Error en la salida**, estructura OE, calculado por:

$$\varepsilon(t) = y(t) - \frac{b_1 + b_2 q^{-1}}{1 + f_1 q^{-1}} u(t-1) \approx v(t) \quad 5.14$$

en donde el error o residuo solo está afectado por el histórico de las entradas.

b) Con respecto a los algoritmos utilizados en los métodos de identificación, se puede distinguir entre **algoritmos recursivos o algoritmos no recursivos**. En el primer caso la estimación de los parámetros se realiza después de cada nuevo conjunto de datos, utilizando el valor de los parámetros estimados con un conjunto de datos como punto de partida para la estimación de los parámetros para el conjunto de datos posterior. Con el algoritmo no recursivo se utilizan secuencias enteras que comprenden todos los datos almacenados para calcular en un solo paso el valor de los parámetros.

c) Con el hecho de disponer de un ordenador para realizar la identificación del modelo, podemos distinguir entre dos formas de acoplar el proceso con

el ordenador, son las denominadas: **operación on-line (acoplamiento directo)** y **operación off-line (acoplamiento indirecto)**. En el caso **off-line** se almacenan los datos adquiridos del proceso y posteriormente se transfieren al ordenador para ser evaluados y procesados. Ya que este tipo de identificación se realiza sobre un conjunto de datos, puede considerarse como un proceso en lote (**batch processing**). Cuando se trabaja en **on-line** los datos son directamente procesados dando lugar a lo que se denomina **procesado en tiempo real** o **batch processing** cuando los datos son evaluados después de realizarse un conjunto de medidas. Las distintas formas de procesar los datos se describen en la Figura 5.1.

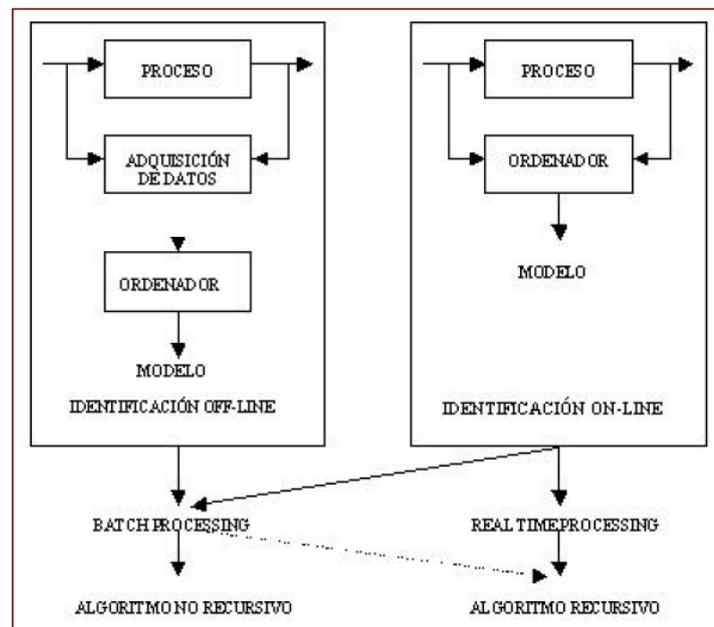


Figura 5.1
Métodos de procesamiento de datos para modelamiento

Los métodos de identificación pueden clasificarse también en función de los modelos obtenidos, de esta forma podríamos diferenciar entre:

técnicas de identificación no paramétricas, obteniéndose modelos no paramétricos, y **técnicas de identificación paramétricas**, que conducen modelos paramétricos. Dentro de las denominadas **técnicas de identificación no paramétricas** podemos citar como más importantes:

(1) **Análisis de la respuesta transitoria** se basa en la obtención de la respuesta del sistema a un impulso o a un escalón. Las señales de test a utilizar en este caso son un impulso o un escalón, respectivamente, y la salida registrada da el modelo correspondiente.

(2) **Análisis de correlación** es un método del dominio temporal, útil para sistemas lineales y con señales continuas o discretas. Como resultado del mismo se obtiene la función de correlación entre las variables de interés y, como caso especial, una función de pesos.

(3) **Técnicas frecuenciales** que son utilizadas directamente para estimar la respuesta frecuencial del sistema. Dentro de las técnicas frecuenciales podemos diferenciar entre el **análisis de Fourier** y el **análisis Espectral**.

Todas ellas son aplicables en el caso de considerar procesos lineales o linealizables. Para su utilización no se debe suponer ningún tipo de estructura para el modelo y los resultados obtenidos son de tipos gráfico los cuales pueden ser más o menos fáciles de interpretar.

En el caso de **métodos de identificación paramétricos**, se debe tener en cuenta una cierta estructura para el modelo. Los parámetros del

modelo se calculan minimizando ciertos criterios de error entre el modelo y el proceso. En general podemos distinguir entre dos tipos de técnicas:

- **Técnicas frecuenciales**, las cuales minimizan el error entre la respuesta frecuencial real del proceso y la respuesta frecuencial del modelo;
- **Técnicas temporales**, las cuales minimizan el error temporal, error de predicción o error de salida, entre el modelo y el proceso. Forman parte de este grupo los métodos de identificación paramétricos clásicos y con redes neuronales.

Ambas pueden ser utilizadas tanto para la estimación de los parámetros de modelos continuos como discretos.

3. Etapas a seguir en la identificación de un modelo

En general, las etapas a seguir para identificar un modelo paramétrico son:

- **Diseño del experimento de identificación.** En esta primera etapa es necesario decidir, entre otros aspectos: el tipo de señales de excitación, el mejor periodo para la adquisición de datos, la cantidad de datos necesarios.
- **Observación y mejora de la calidad de los datos capturados.** Antes de utilizar los métodos de estimación de parámetros es

necesario: observar y reparar los datos erróneos, filtrar las altas frecuencias, eliminar offsets y tendencias, etc.

- **Determinación de la estructura del modelo.** En esta etapa es necesario definir el tipos de modelos a utilizar: continuos o discretos, tipos de ruido, lineales o no lineales, regresiones, redes neuronales, etc. Y es necesario adoptar un procedimiento para determinar el orden del modelo.
- **Estimación de los parámetros.** Etapa la mayoría de las veces muy relacionada con la anterior, en ella se presenta el problema de decidir el método o métodos de estimación de parámetros que se va a utilizar para calcular el valor de los mismos. En general se puede escoger entre dos técnicas distintas: en el dominio temporal y en el dominio frecuencial.
- **Validación del modelo.** Es la etapa en la que debe preguntarse si el modelo identificado es suficientemente representativo del proceso estudiado. En el se debe definir un criterio para evaluar la calidad. Generalmente se dispone de varios modelos candidatos y debe escogerse uno de ellos basándose en algún criterio.

Actualmente hay muchos programas comerciales de ayuda a ingeniero en las etapas de identificación, concretamente en las etapas de estimación de parámetros y evaluación de las propiedades del modelo estimado. Hay otras etapas que dependen exclusivamente del usuario

[Ljung94]. En esta tesis se utilizará como herramienta de trabajo el programa Matlab y concretamente el toolbox de identificación.

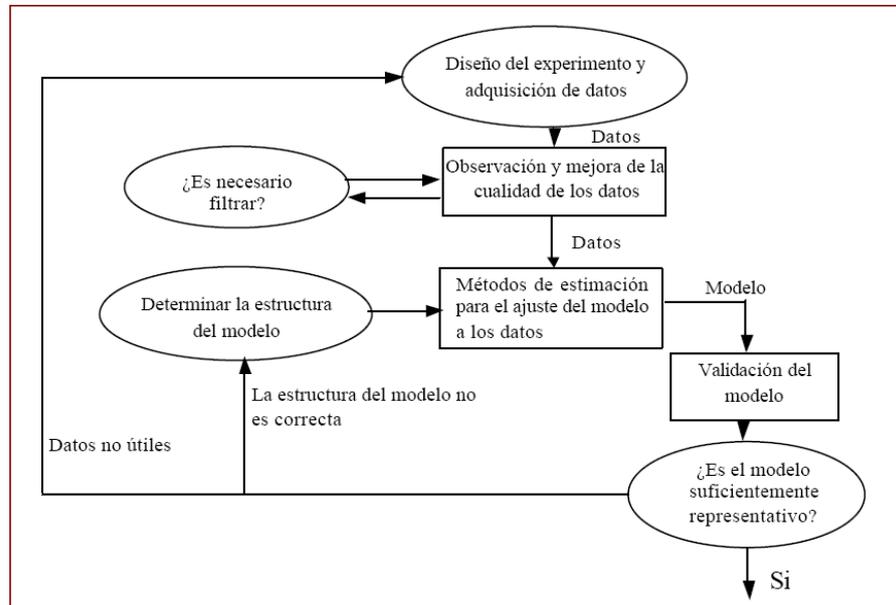


Figura 5.2
Algoritmo general para el modelamiento de sistemas
 Fuente: Propia

4. Relación entre modelos y métodos

Para finalizar con los fundamentos del modelado se podría remitir a (Iserman, 1980) exponiendo de forma resumida la dependencia existente entre la construcción del modelo y su objetivo final o aplicación.

Tabla 5.1
Ejemplos de la relación existente entre el objetivo final del modelo (aplicación) y las especificaciones del proceso de identificación.

Objetivo final del modelo, aplicación	Tipos de modelos	Requerimientos de precisión del modelo	Método de identificación
verificación de modelos teóricos	lineal, tiempo continuo, no paramétrico/paramétrico	media / alta	off-line, respuesta transitoria, respuesta frecuencial, estimación paramétrica
Sintonía de controladores	lineal, no paramétrico, tiempo continuo	medio	off-line, respuesta transitoria
Ayuda al diseño de algoritmos de control	lineal, paramétrico, (no paramétrico) tiempo discreto	medio	estimación paramétrica on-line / off line
Control adaptativo	lineal, paramétrico, tiempo discreto	medio	estimación paramétrica on-line
Supervisión y detección de fallos	lineal / no lineal, paramétrico, tiempo continuo	alto	estimación paramétrica on-line

Fuente: Propia

5.3. DISEÑO

El diseño de un modelo de simulación depende principalmente del fin que se le quiera dar. En el caso de este estudio el fin fundamental es la optimización del consumo de energía, por lo cual se hará especial énfasis en el cálculo de la energía en función de las demás variables. Cabe tener en cuenta, que muchos de errores en el momento de modelado, se dan debido a que no se tiene su utilidad clara, y se da un énfasis en demasía en el modelado para control de procesos.

La Figura 5.3 muestra un ejemplo de aplicación de un modelo en una planta industrial. En este caso se observa cual es la visión global de los modelos en la

supervisión, control y predicción de la planta, y de qué manera podría interactuar con el resto de instrumentación.

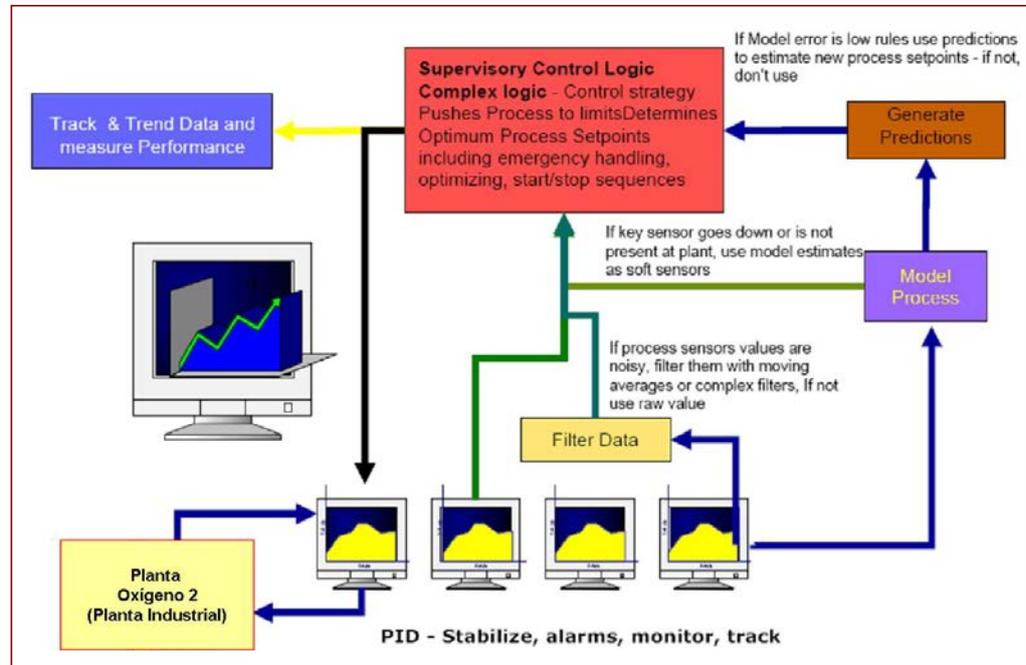


Figura 5.3
Modelos en la visión global de una planta
Fuente: Metso minerals

Ahora, pasando al ejemplo práctico, se definen las áreas a simular. La fundición de Ilo, presenta 14 áreas definidas en el capítulo II. Como se apuntó en su momento, se seleccionaron para el modelado aquellos procesos de mayor consumo. Para el resto de procesos se considera un consumo eléctrico constante y periódico. La Tabla 5.2 muestra las plantas simuladas a profundidad.

Tabla 5.2
Plantas simuladas a profundidad

N°	Planta
1	Planta de oxígeno 2
2	Planta de oxígeno 1
3	Planta de ácido 2
4	Planta de ácido 1
5	Toma de agua de mar

Fuente: Propia

El modelamiento fue realizado por un equipo de trabajo, estando cada planta a cargo de una persona diferente. Debido a la complejidad de cada uno de los procesos a modelar, el equipo estaba conformado por un grupo interdisciplinario de ingenieros, si bien es cierto cada uno estaba a cargo de una planta en particular, todos podían participar como soporte en el resto de plantas.

En la Figura 5.4, se muestra el diagrama de bloques general utilizado para la simulación de la Fundición de Ilo.

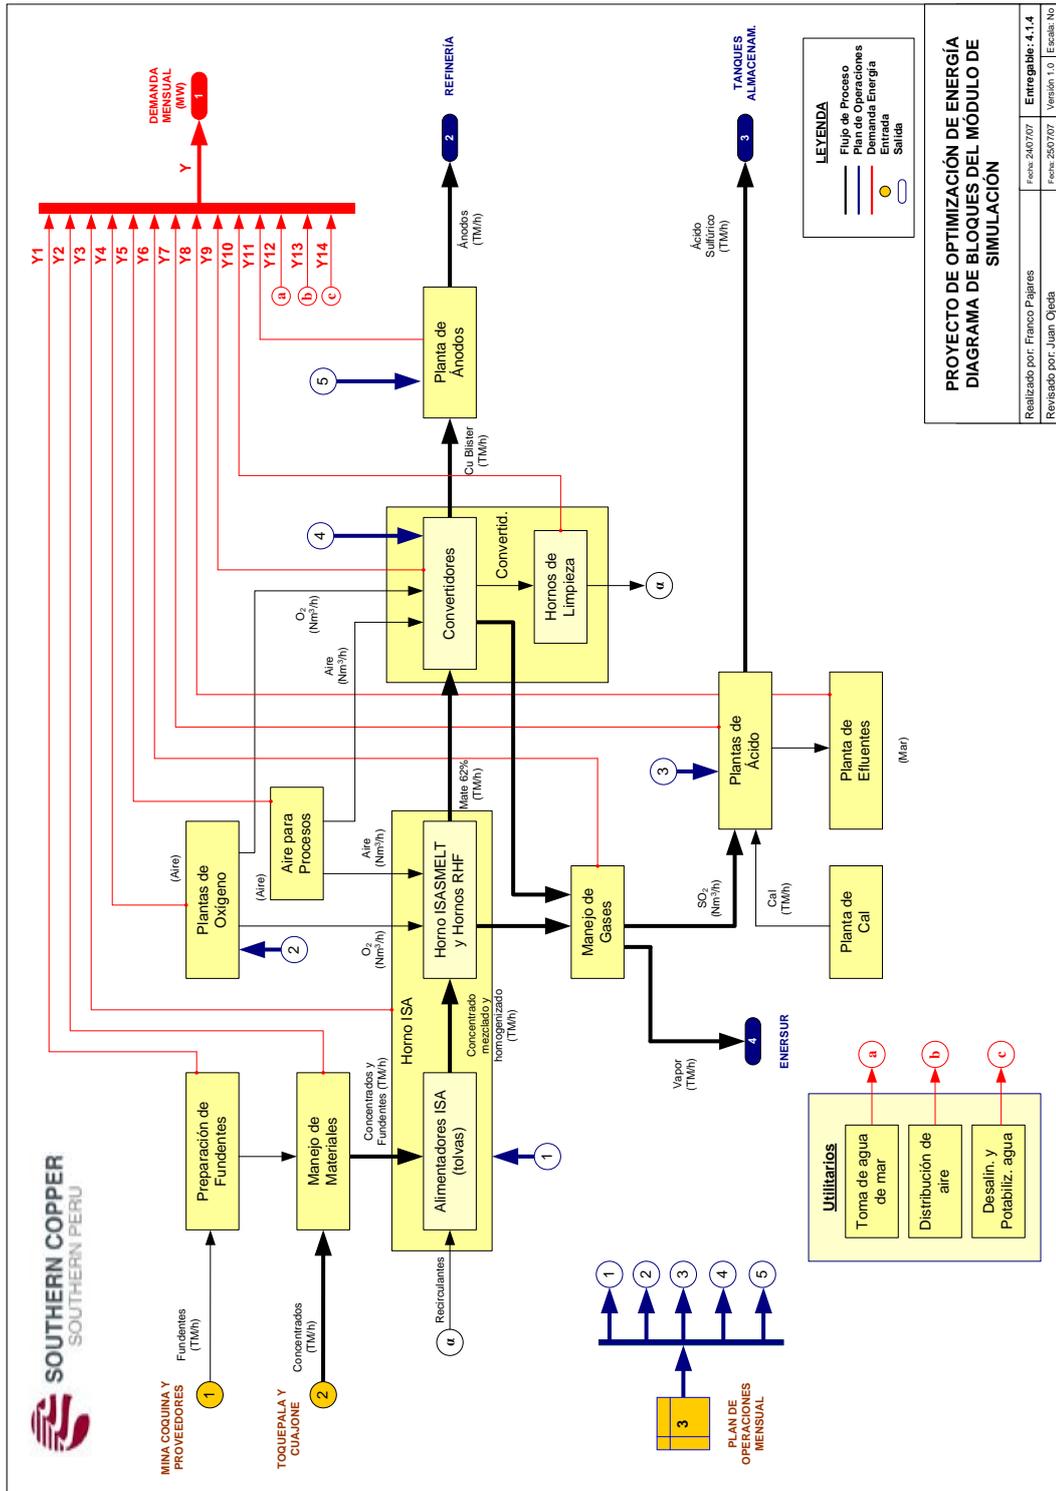


Figura 5.4
 Diagrama de Bloques General de la Fundición de Ilo
 Fuente: SCC. Elaboración: Propia

Como el desarrollo del modelamiento total es extenso y diferente para cada planta, se procederá a explicar cómo se realizó el modelamiento de la **planta de oxígeno 2 (POX2)**, replicando su comportamiento para las demás plantas. La planta de oxígeno 2 es la de mayor importancia, debido a que constituye la de mayor consumo de toda la Fundación.

5.3.1. Definición de fronteras

La planta de oxígeno 2 (POX2) es la planta de mayor consumo de la Fundación de Ilo. Esta planta está encargada de destinar los productos de una planta de separación criogénica de aire, que pueden ser oxígeno, nitrógeno, y argón, se obtienen comprimiendo, purificando, enfriando, licuando, y luego destilando el aire.

Los principales equipos usados para lograr la separación criogénica del aire incluyen:

- Compresor(es) de aire
- Recipientes de purificación de aire
- Expansor (es) o compander (es)
- Los equipos instalados en cajas frías.

Además, se necesitan equipos auxiliares como sistemas de control, analizadores, y un sistema de enfriamiento. Se pueden necesitar compresores de productos, estanques de almacenamiento y vaporizadores.

Un compresor de aire comprime el aire a la presión requerida por el proceso de separación del aire. El aire comprimido contiene impurezas. Agua y dióxido de carbono se eliminan por adsorción en los recipientes de purificación del aire. Los hidrocarburos también se eliminan hasta un nivel seguro por adsorción. Los adsorbentes se reactivan para eliminar estas impurezas, y las impurezas se sueltan en la atmósfera.

El aire limpio seco se envía a las cajas frías, que son estructuras aisladas que contienen los intercambiadores de calor, las columnas de destilación, y otros equipos requeridos por el proceso de destilación.

El exceso de producto o el producto de respaldo puede almacenarse en tanques de almacenamiento criogénico para ser usado en tiempos de alta demanda, períodos inactivos o para transportarlo a otras instalaciones o clientes.

5.3.2. Definición de subsistemas

Para definir los subsistemas a ser simulados, se consideró el diagrama de flujo del proceso, así como los documentos ya existentes tanto de la empresa como del vendor que instaló la planta.

La Unidad de Separación de Aire (ASU) produce oxígeno gaseoso puro (GOX) usando un proceso de destilación criogénica. Este proceso implica completar múltiples operaciones unitarias.

- Colectivamente, estas distintas operaciones unitarias son:
- Filtración, Compresión y Eliminación de Calor y Condensado del Aire Ambiental

- Purificación del Aire
- Intercambio de Calor
- Destilación del Aire
- Refrigeración
- Entrega del Producto
- Respaldo del Producto

La ASU está diseñada con una columna de destilación doble, un Intercambiador de Calor Principal y otros recipientes y equipos del proceso que funcionan juntos para producir una corriente continua del producto oxígeno. Los equipos de la planta también incluyen un Tanque de Almacenamiento de oxígeno líquido (LOX) y un vaporizador de LOX que juntos sirven como sistema de respaldo de suministro del producto. En seguida se da una breve descripción de las principales operaciones unitarias en la planta.

La descripción del proceso se puede seguir en el Diagrama de Flujo del Proceso de los P&ID.

Generalidades

La planta está provista de un Sistema Frontal de Adsorción para purificación y limpieza del aire. El producto oxígeno será producido por un ciclo de proceso de ebullición de LOX, y se entregará desde la planta a la presión requerida sin bombas de LOX o un compresor de producto GOX.

Este ciclo de proceso tiene las ventajas de alta confiabilidad, bajo costo de mantenimiento e instalación y operación simple.

Compresión del aire

El aire ingresa a través de dos filtros de entrada (V102 A/B) para eliminar polvo y material particulado antes de entrar a los Compresores de Aire Principales (K111 A/B). El enfriamiento del aire del proceso entre etapas lo proporcionan enfriadores. El aire que sale de los compresores se enfría con alguna eliminación de agua en la Torre de Lavado (DCAC C161). La Torre de Lavado está constituida por dos secciones. La sección superior (Enfriador de Desecho C171) es alimentada con agua fría para enfriamiento producida contactando agua de enfriamiento, del circuito cerrado de la planta, con nitrógeno seco de desecho proveniente de la Caja Fría, en la Torre Enfriadora de Desecho (C171). La sección inferior de la Torre de Lavado es alimentada con agua de enfriamiento del circuito cerrado de la planta que se mezcla con el agua de enfriamiento entibiada proveniente de la sección superior. El agua enfriada de la parte de abajo de la Torre Enfriadora de Desecho (G171) es bombeada a la parte de arriba de la Torre de Lavado.

Limpieza y enfriamiento del aire

Antes de enfriar el aire a temperaturas criogénicas, se elimina agua y dióxido de carbono en la unidad purificadora de aire “Temperature Swing Adsorber” (TSA) C182 A/B. La eliminación de dióxido de carbono y agua evita el bloqueo de los equipos criogénicos. La eliminación de impurezas

resulta en una corriente de aire limpio y seco. El sistema opera en un ciclo alternado, es decir que un recipiente esta adsorbiendo las impurezas contenidas mientras la otra esta siendo reactivado con nitrógeno gaseoso de desecho. El aire instrumental seco requerido durante la operación normal también será proporcionado por este sistema.

Después del Sistema Adsorbedor, la corriente de aire se divide en dos corrientes. La primera corriente se comprime en el Compresor Booster (K131) y se enfría en el Postenfriador (E136) antes de ser enfriado en el Intercambiador de Calor Principal (E201). Una parte de esta corriente a alta presión se retira del Intercambiador de Calor Principal en un punto intermedio, se expande por una válvula para producir refrigeración por el efecto de Joule-Thomson (JT), y se alimenta a la Columna de Baja Presión (C212) como aire líquido. El resto de este aire se enfría más en el Intercambiador de Calor Principal, y se alimenta a la Columna de Baja Presión (C211) como una corriente de aire líquido subenfriado.

La segunda corriente de aire del Adsorbedor se enfría en el Intercambiador de Calor Principal. Una porción de esta corriente de aire se retira del Intercambiador de Calor Principal a una temperatura intermedia, se entrega al Expander (K262) para producir refrigeración y se alimenta a la parte central de la Columna de Baja Presión (C212). La porción que queda de esta corriente de aire del Sistema Adsorbedor se enfría aun más en el Intercambiador de Calor Principal antes de alimentarla a la parte inferior de la Columna de Alta Presión (C211).

Las necesidades de refrigeración más altas se producen durante la puesta en marcha y el enfriamiento de la planta, cuando se debe eliminar el calor de la planta y de los equipos calientes, y mientras se acumula un inventario líquido. Una vez que la planta alcanza su temperatura de operación, la refrigeración requerida compensa la producción de líquido, las diferencias de temperatura del lado caliente de los intercambiadores principales y los escapes de calor hacia el exterior.

Columna de alta presión

La alimentación de aire a la Columna de Alta Presión sube a través de las bandejas de destilación y hierve el líquido en las bandejas. El nitrógeno, más volátil, se separa del líquido por ebullición, mientras que el intercambio de calor latente condensa oxígeno del aire que pasa por las bandejas.

Como resultado de esto, los vapores que suben por la columna aumentan constantemente su contenido de nitrógeno, mientras que el líquido en el depósito de la columna se va enriqueciendo con oxígeno. El oxígeno líquido crudo se retira del depósito de la columna de alta presión y se evapora rápidamente a la columna de baja presión.

Los vapores enriquecidos con nitrógeno se condensan en el Rehervidor-Condensador (E213) debido al intercambio de calor con el oxígeno líquido que se está evaporando en el depósito de la Columna de Baja Presión. Una parte del nitrógeno condensado vuelve a la Columna de Alta Presión como reflujo. El resto del reflujo de nitrógeno se enfría en el E201 antes de evaporarlo rápidamente a la Columna de Baja Presión.

Columna de baja presión

La purificación final del oxígeno se produce en la Columna de Baja Presión. El proceso de destilación en la Columna de Baja Presión es esencialmente igual que en la Columna de Alta Presión. El oxígeno líquido en el depósito de la Columna de Baja Presión, sin embargo, ha pasado por más etapas de destilación y es más puro.

El producto oxígeno se retira del fondo de C212 como un líquido y va al Intercambiador de Calor Principal donde se vaporiza y calienta contra el aire a alta presión antes de salir de la Caja Fría a la presión de entrega del producto. Una pequeña parte del oxígeno líquido puede retirarse antes del Intercambiador de Calor Principal y entregarse al tanque de almacenamiento de LOX. No se necesita bombeo en este ciclo del proceso para alcanzar la presión de entrega del producto GOX.

El nitrógeno de desecho se retira de la Columna a Baja Presión y se calienta en el Intercambiador de Calor Principal antes de salir de la Caja Fría. Una parte de la corriente de nitrógeno de desecho se usa para la reactivación de los Adsorbedores TSA. El resto del gas de desecho se usa para enfriar agua en la Torre Enfriadora de Desecho (C171) antes de liberarlo a la atmósfera.

Entrega del producto

El oxígeno retirado del fondo de la C212 como líquido entra al Intercambiador de Calor Principal, donde se vaporiza y se calienta. Sale de la

Caja Fría a la presión de entrega del producto. Una válvula controla el flujo de GOX antes de pasarlo a la tubería del producto.

Sistema de respaldo del producto

Una pequeña porción del oxígeno líquido puede retirarse antes del Intercambiador de Calor Principal y enviarse al Tanque de Almacenamiento de LOX. El sistema de respaldo del producto está constituido por el Tanque de LOX T622 y el Vaporizador de Producto LOX E641.

El sistema de almacenamiento y vaporización de LOX está diseñado para proporcionar respaldo instantáneo de producto oxígeno cuando sea necesario. El oxígeno líquido se alimenta automáticamente del Tanque de Almacenamiento de LOX al Vaporizador de Producto E641 cuando la presión en la tubería lo exige. Este LOX se vaporiza y se calienta por contacto indirecto con agua de enfriamiento antes de introducirlo en la tubería del producto oxígeno.

Un Tanque de Almacenamiento lleno proporciona respaldo de flujo de GOX a 1045 TM por día.

5.3.3. Definición de variables

La definición de variables a utilizar, se debe realizar de acuerdo a la importancia que presenten en el proceso y la posibilidad de su medición. En el caso de la planta de oxígeno se cuentan con 38 variables principales, 35 de las cuales presentan sensores. Las variables más relevantes en la planta de oxígeno, se muestran en la Tabla 5.3.

Tabla 5.3
Variables de la Planta de Oxígeno 2

Nº	Variable	Descripción	Unidad	Subsist.			Tipo		
				Eléctrica	Proceso	Control	Entrada	Intermedia	Salida
1	SP1	Set Point Flujo Descarga	KNm ³ /h			X	X		
2	SP2	Set Point Apertura Válvula LAIR a C211	%			X		X	
3	SP3	Set Point Apertura Válvula LOX a T622	%			X		X	
4	SP4	Set Point Apertura Válvula GOX a consumidores	%			X		X	
5	SP5	Set Point Apertura Válvula GOX a venteo	%			X		X	
6	N1	Velocidad del motor de MAC K111	RPM			X	X		
7	N2	Velocidad del motor de BAC K131	RPM			X	X		
8	F1	Flujo de descarga de aire de las MAC	KNm ³ /h	X				X	
9	F2	Flujo de entrada al TSA del DCAC de aire	KNm ³ /h	X				X	
10	F3a	Flujo de entrada al Booster de aire del TSA	KNm ³ /h	X				X	
11	F3b	Flujo de entrada a E201 de aire del TSA	KNm ³ /h	X				X	
12	F4	Flujo de entrada a E201 de aire del Booster	KNm ³ /h	X				X	
13	F5	Flujo de entrada a C211 de LAIR del E201	KNm ³ /h	X				X	
14	F6	Flujo de entrada a C212 de LAIR del E201	KNm ³ /h	X				X	
15	F7	Flujo de entrada a K262 de aire del E201	KNm ³ /h	X				X	
16	F8	Flujo de entrada a C211 de aire del E201	KNm ³ /h	X				X	
17	F9	Flujo de entrada a E201 de LOX de C212	KNm ³ /h	X				X	
18	F10	Flujo de salida de E201 de GOX a distribución	KNm ³ /h	X				X	
19	F11	Flujo de salida de K262 de aire a C212	KNm ³ /h	X				X	
20	F12	Flujo de salida de GOX a consumidores	KNm ³ /h	X					X
21	F13	Flujo de salida de GOX a venteo	KNm ³ /h	X					X
22	F14	Flujo de CLOX de C211 a C212	KNm ³ /h	X				X	
23	F15	Flujo de LIN de C211 a C212	KNm ³ /h	X				X	
24	F16	Flujo de LOX a T622	KNm ³ /h	X				X	
25	Pr1	Presión de descarga de las MAC	barg	X				X	
26	Pr2	Presión de salida del DCAC	barg	X				X	
27	Pr3	Presión de salida del TSA	barg	X				X	
28	Pr4	Presión de descarga del Booster	barg	X				X	
29	T1	Temperatura de descarga de las MAC	°C	X				X	

30	T2	Temperatura de salida del DCAC	°C		X			X	
31	T3	Temperatura de salida del TSA	°C		X			X	
32	T4	Temperatura de salida del Booster	°C		X			X	
33	P1	Potencia de las MAC	KW	X				X	
34	P2	Potencia del calefactor del TSA	KW	X				X	
35	P3	Potencia del Booster	KW	X				X	
36	P4	Potencia del Expansor	KW	X				X	
37	P	Potencia Total	KW	X					X
38	E	Energía mensual	KW	X					X

Fuente: SCC. Elaboración: Propia

Estas variables han sido consideradas teniendo en cuenta su relevancia en el proceso, los lazos de control y la interacción con el horno ISASMELT, principal cliente de la planta.

5.3.4. Análisis de caso de uso

La planta de oxígeno 2 consume 9,504,000 KWh mensual, lo cual representa el 33.19% de energía total de la Fundición Ilo. Además presenta una demanda media de 13.2 MW y una demanda máxima mensual de 14.35 MW. En la Figura 5.5 se muestra la evaluación de su demanda en un día de operación normal.

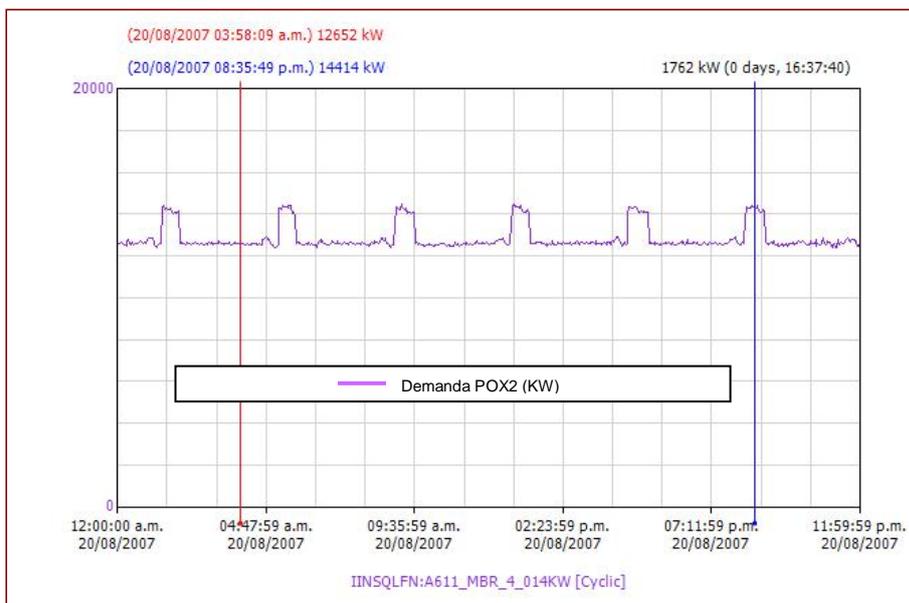


Figura 5.5
Demanda (KW) de la POX2 en un día de operación normal
 Fuente: SCC (Active Factory. 20 agosto 2007)

Esta curva es continua durante todo el mes, así el horno ISA y las demás plantas dejen de operar. Actualmente la demanda de oxígeno es intermitente y depende de la disponibilidad del horno ISA, tal como se muestra en la Figura 5.6. Sin embargo, la producción de oxígeno sigue estando en sus niveles máximos no habiendo la posibilidad de regulación de este flujo, como se ve en las líneas verticales roja y azul del mismo gráfico, donde a pesar que el requerimiento en la lanza del ISA sea nulo, la producción sigue estando en sus niveles máximos de 31,145 Nm³/h de oxígeno al 95% de pureza.

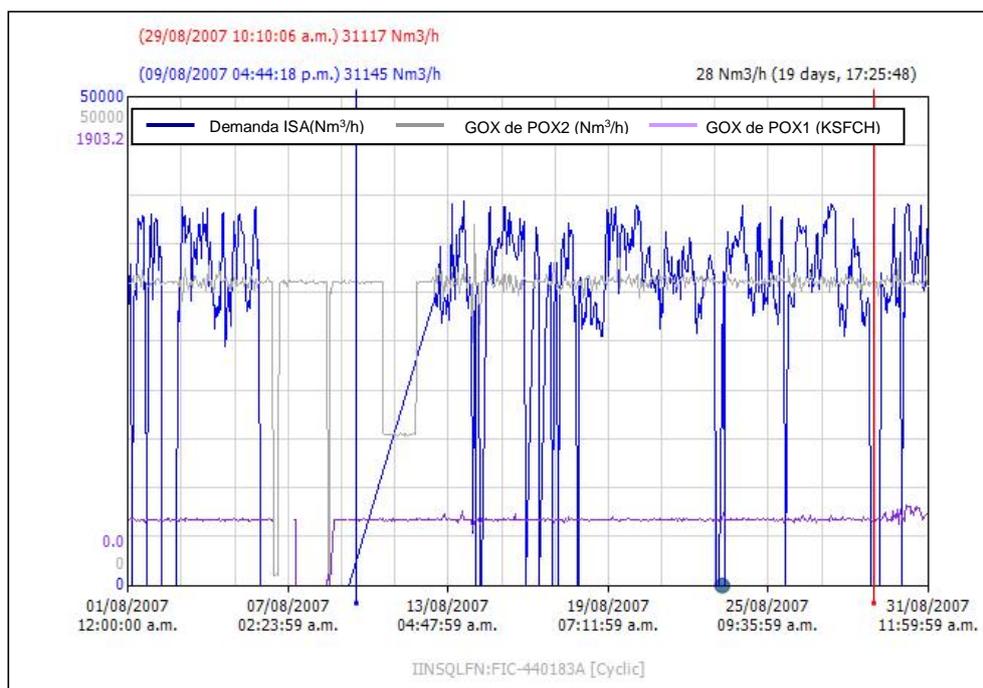


Figura 5.6
Balance de oxígeno de la fundición Ilo
 Fuente: SCC (Active Factory. Agosto 2007)
 Elaboración: Propia

Las razones de la continuidad en la operación de la POX2, se dan debido a la dificultad de puesta en marcha ya que se trabaja con temperaturas de criogenización, motivo por el cual sólo se la apaga en períodos grandes de para de producción (ref. 07/08/07 – 12/08/07, Figura 5.6).

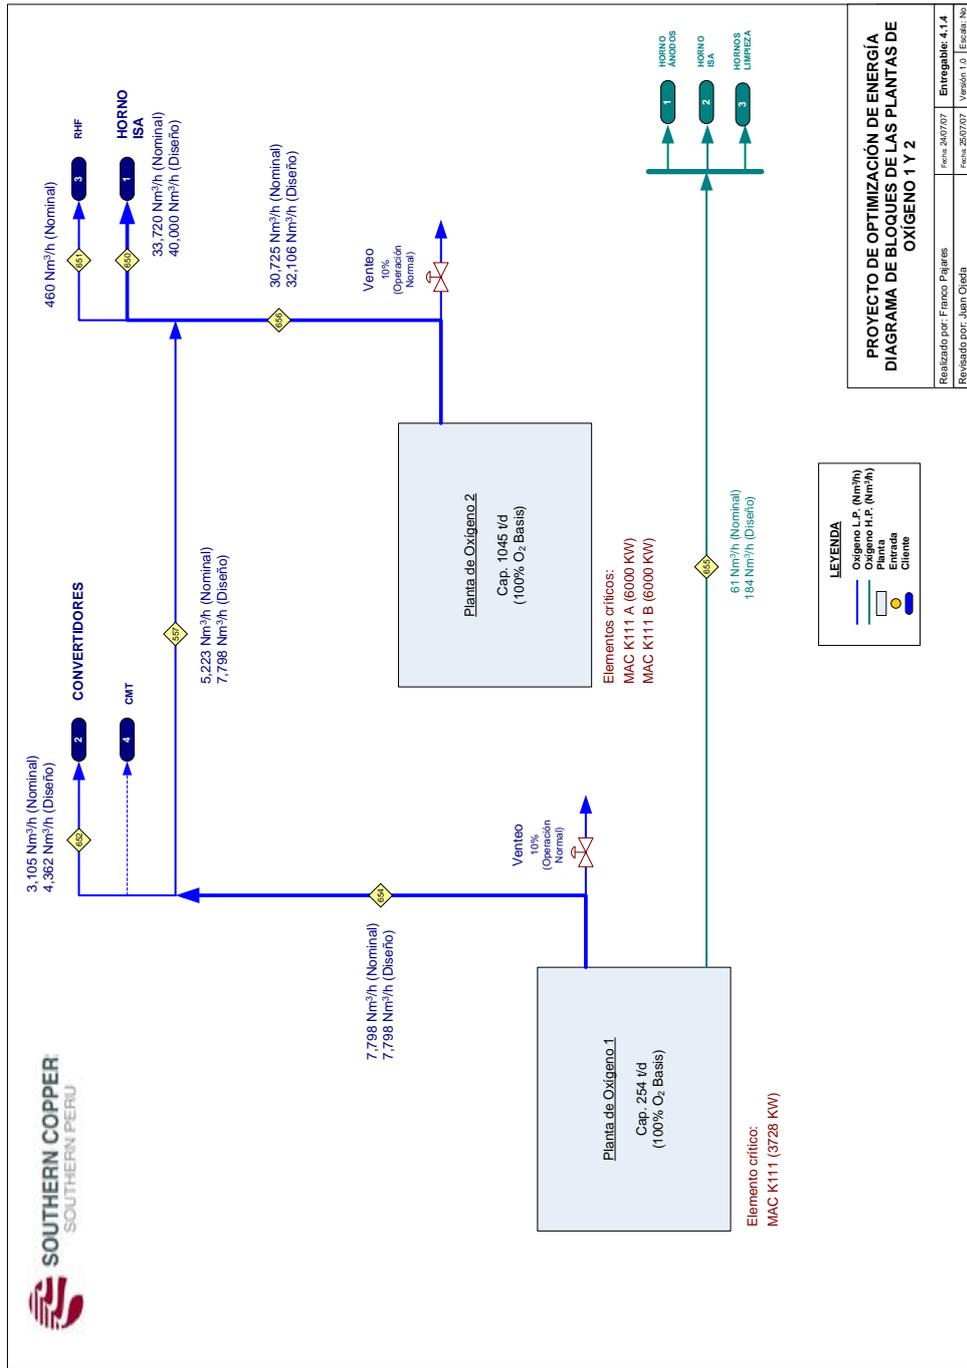


Figura 5.7
Diagrama de flujo de las plantas de oxígeno
Fuente: SCC. Elaboración: Propia

5.3.5. Modelo matemático

El modelamiento matemático es una de las etapas más importantes en el desarrollo de la tesis. Tal como se definió en la Sección 5.1. Fundamentos, los modelos son muy variados y dependen de una gran cantidad de factores: tipo de ecuaciones (diferenciales, ordinarias, grado), tipo de software, poder computacional, capacidad de conexión a la red industrial. Sin embargo, el punto principal a ser tomado en cuenta al momento de la realización de un modelo, es la efectividad del mismo. Es decir, cuán bien sigue el modelo a la realidad, teniendo en cuenta que por más perfecta que sea la matemática y el análisis del mismo, siempre van a existir perturbaciones que pueden cambiar totalmente los parámetros seleccionados, las condiciones iniciales y el sistema en sí. Por tal motivo, se debe cuidar que el modelo sea robusto para un amplio espectro de data de entrada, tal como lo haría el sistema en la realidad. Esto significa una gran cantidad de pruebas, y diversos modelos, luego del análisis matemático inicial. A continuación se presenta el modelamiento para el caso tratado en la tesis.

De acuerdo a la planta seleccionada para su modelamiento (Planta de oxígeno 2), se definieron las principales equipos y procesos involucrados en el consumo eléctrico. Para calcular la potencia total (KW) de la POX2 en función de tiempo, se requieren conocer que potencias la conforman. En la Tabla 5.4, se muestran los equipos que demandan potencia eléctrica, así como sus respectivos valores de potencia y energía.

Tabla 5.4
Equipos eléctricos de la POX2. Consumos, demandas y cargo

Equipo/Planta	KW	KWh	Variable
POX2	13,200	9,504,000	P
MAC K111 A	5,700	4,104,000	P1a
MAC K111 B	5,900	4,248,000	P1b
BAC K131	1,400	1,008,000	P3
Expansor K162	(500)	(360,000)	P4
Bombas CW	372	267,840	P5
Calefactor (TSA)	1,755*	236,925	P2

Fuente: Planos de cada equipo (SCC)

Elaboración: Propia

Donde:

- MAC : Compresor Principal K111
- BAC : Compresor Booster K131
- Bomb. CW : Bombas para agua de enfriamiento
- TSA : Absorbedores

Por lo tanto, de la definición de variables realizada en el ítem 4.1.3.,
la potencia total de la POX 2, será:

$$P = P_{1a} + P_{1b} + P_2 + P_3 + P_4 + P_5 \quad 5.15$$

El objetivo ahora es encontrar las relaciones de proceso y control que influyan en la variación de cada uno de los elementos que conforman la potencia final (KW) en el tiempo.

Debido a que las compresoras MAC (Main Air Compressors), son los equipos de mayor demanda y consumo eléctrico, se realizará un estudio detallado de la influencia de las variables de proceso en sus potencias P_{1a} y P_{1b} .

En el caso de las compresoras y de acuerdo a las tablas de fabricante, la potencia eléctrica¹⁷, varía de acuerdo al flujo de descarga. Sin embargo, debido a la falta de un flujómetro dedicado a cada compresor, se obtuvo la potencia de acuerdo al flujo de ingreso, el cuál viene dado por el porcentaje de apertura de las válvulas IGV (Inlet Ga Valves). En la Figura 5.8, se muestra la variación de la potencia y de los porcentajes de apertura de las IGV en un día normal de operación.

¹⁷ Nótese que se habla de potencia eléctrica y no de potencia en el freno, que es la que normalmente se presenta en los datos de fabricante.

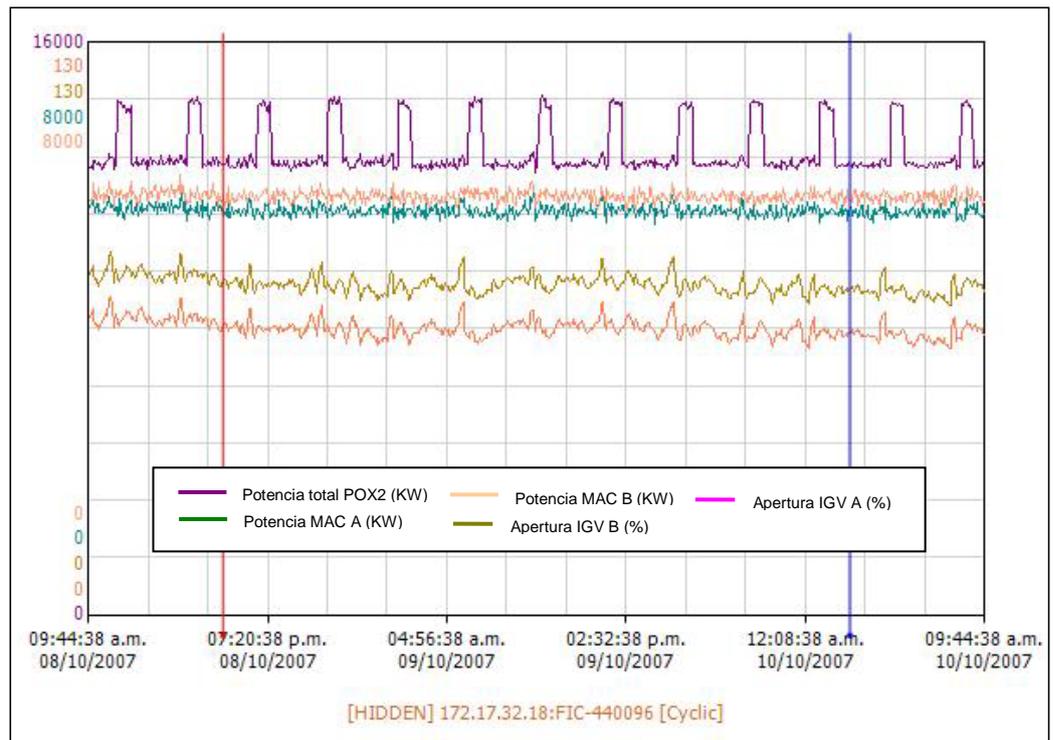


Figura 5.8
Potencia y porcentaje de apertura de las IGV de las Compresoras
MAC en el tiempo

Fuente: Active Factory

En la Figura 5.9, se muestra la relación entre el porcentaje de apertura de las IGV y la potencia. Nótese, que existe una gran dispersión entre los valores muestreados; sin embargo, se puede distinguir en promedio una tendencia lineal. Por lo cual podemos concluir que la potencia eléctrica varía de manera proporcional al porcentaje de apertura de las IGV.

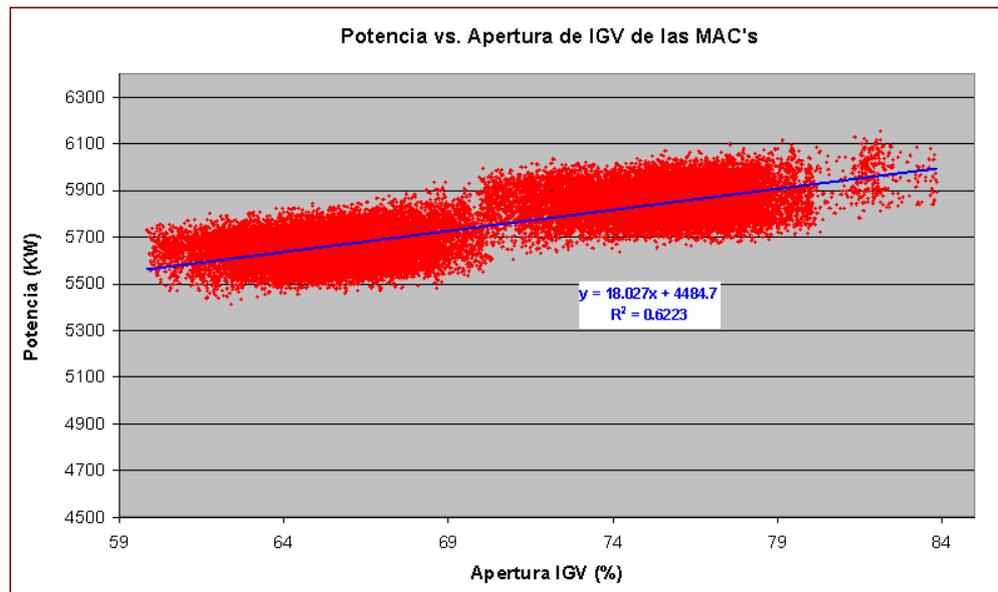


Figura 5.9
Potencia vs. porcentaje de apertura de las IGV de las Compresoras MAC
 Fuente: Active Factory (Query). Elaboración: Propia

La ecuación matemática que relaciona a la potencia eléctrica y el porcentaje de apertura de las IGV de las MAC, se obtuvo de una regresión lineal y es la siguiente:

$$\begin{aligned} P_{1a} &= 18.027H_1 + 4484 \\ P_{1b} &= 18.027H_2 + 4599 \end{aligned} \quad 5.16$$

Donde:

$$F_1 = K(H_1 + H_2) \quad 5.17$$

En este análisis, se basa la propuesta de ahorro 3, en la cual se propone configurar adecuadamente los lazos de control para llevar las

variables de proceso (flujo y presión de descarga) a las condiciones de diseño; es decir, 72,248 Nm³/h y 4.66 barg.

La variable crítica a controlar en el caso de las compresoras es la presión de descarga, la cual debe estar en 4.66 barg ó 5.66 bara aproximadamente. Por tal fin, al realizar cualquier modificación en los compresores, se debe tener presente su influencia en dicha variable. Luego de los estudios e investigaciones realizadas en los últimos artículos e investigaciones para compresores centrífugos, se selecciona la relación cúbica de Moore y Greitzer, para determinar la influencia del flujo másico (\dot{m}_c) y la velocidad del motor (N) en la presión de descarga. Se tiene la siguiente ecuación:

$$\Delta p_c(\dot{m}_c, N) = \Delta p_c(0, N) + H(N) \left[1 + \frac{3}{2} \left(\frac{\dot{m}_c}{W(N)} - 1 \right) - \frac{1}{2} \left(\frac{\dot{m}_c}{W(N)} - 1 \right)^3 \right] \quad 5.18$$

Los parámetros $\Delta p_c(0, N)$, H, y W están definidos en la Figura 5.10. Para que la ecuación 1 sea más simple, se la puede aproximar en la nueva relación cúbica:

$$\Delta p_c(\dot{m}_c, N) = a_0(N) + a_2(N)\dot{m}_c^2 + a_3(N)\dot{m}_c^3 \quad 5.19$$

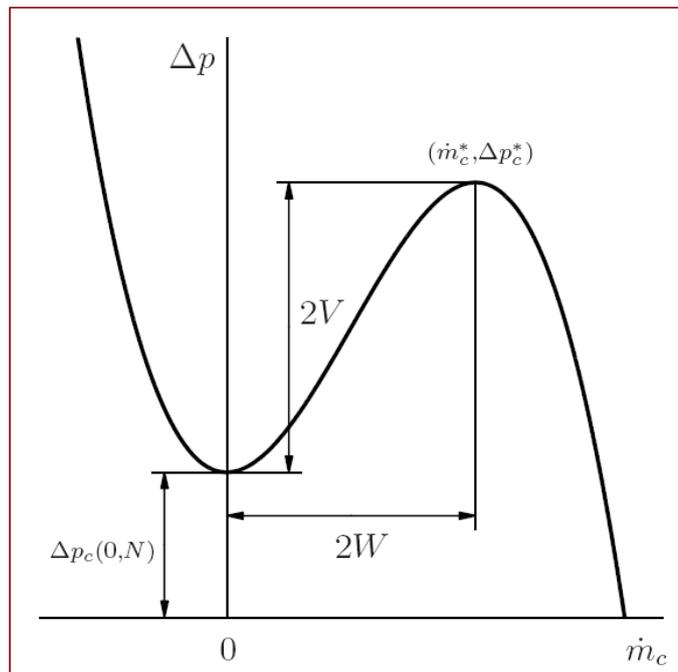


Figura 5.10

Curva característica de un compresor centrífugo

Fuente: Centrifugal Compressor Surge. Modeling and Identification for Control (setiembre 2007)

Como se observa los parámetros $a_0(N)$, $a_2(N)$ y $a_3(N)$ son funciones de la velocidad del motor. De acuerdo a Van Helvoirt¹⁸ (2007), dichos parámetros se pueden aproximar como funciones cuadráticas de la velocidad. Para adecuar las ecuaciones obtenidas de la investigación al caso práctico de las compresoras MAC de la Fundición de Ilo, se modeló el comportamiento a través de un algoritmo en Matlab, donde se realizó un algoritmo capaz de obtener las curvas del compresor en función del flujo másico y la velocidad del motor.

En la Figura 5.11, se muestran las tendencias para las compresoras MAC A y B de la POX2. La línea roja representa la velocidad actual del

¹⁸ Tesis doctoral. Universidad Técnica de Eindhoven para Siemens.

motor es decir 1196 RPM, conforme disminuya la velocidad disminuirá el flujo, pero la presión seguirá constante.

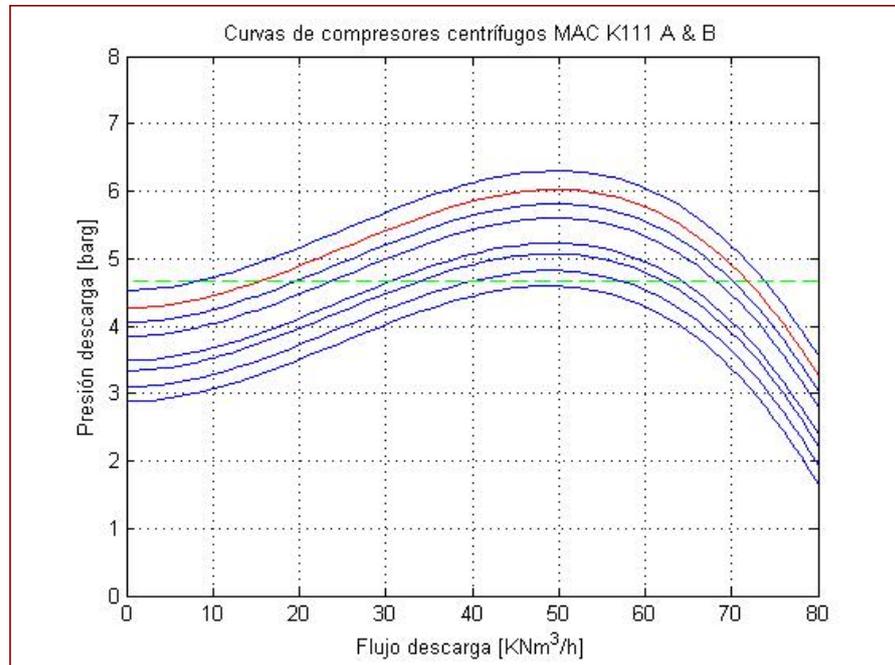


Figura 5.11

Curvas de compresores centrífugos MAC K11 A&B

Fuente técnica: Centrifugal Compressor Surge. Modeling and Identification for Control (setiembre 2007). Elaboración: Propia

El estudio realizado para la presión y la variación del flujo másico y la velocidad del rotor, será de utilidad para cuando se plantee la posibilidad de regular el flujo, ya no utilizando las válvulas IGV, sino a través de variadores de velocidad, los cuales tendrían un efecto mínimo en el cambio de presión, pero sí maximizarían el ahorro de energía.

Para el caso del calefactor eléctrico del TSA, éste responde un sistema batch, es decir opera en periodos constantes de tiempo. Los periodos de encendido y apagado vienen dados por el sistema de limpieza de aire,

desarrollado en los absorbedores C182 del TSA, en los cuales se absorbe la mayor cantidad de CO₂ y gases de hidrocarburos. El calefactor se enciende por periodos de 55 minutos cada 3:50 h aproximadamente. Durante este tiempo, el calefactor se mantiene en su potencia máxima de 1,755 KW.

Esta forma de onda es constante y depende del número de etapas encendidas. Su función matemática por tanto está dada por:

$$P = \begin{cases} 1755 & 0 < t < 55 \text{ min} \\ 0 & \text{otro - caso} \end{cases} \quad T = 3 : 50h$$

5.20

Donde:

- P : Potencia (KW)
 t : Tiempo (minutos)
 T : Periodo (horas)

Para el Compresor Booster BAC K131, el estudio es similar que el realizado para las MAC, sólo que los parámetros se tienen que ajustar de manera diferente, ya que sus condiciones varían en gran medida.

5.4. CONSTRUCCIÓN

5.4.1. Diagrama de bloques

El primer criterio para la simulación de un proceso industrial, es realizar un diagrama que permita combinar las cualidades de un diagrama de flujo (PFD) y de un diagrama de instrumentación (P&ID). Además se deben

considerar las características del programa en el cual se simulará dicho proceso. En el caso de esta tesis, el software utilizado fue Simulink, el cual se basa en bloques de simulación, los cuales representan sistemas mecánicos, eléctricos, electrónicos, de control, etc. Por tal motivo, el diagrama ideal para la simulación de cualquier proceso es un diagrama de bloques que además de combinar las cualidades de los planos PFD y P&ID, permite una rápida integración a cualquier software.

En la Figura 5.12, se muestra un ejemplo de diagrama de bloques para la planta de oxígeno 2, de la Fundición de Ilo, la cual está siendo utilizada en esta tesis como ejemplo de desarrollo.

Como se observa es un diagrama simple que sigue las tendencias de los diagramas PFD y P&ID, ya comentados.

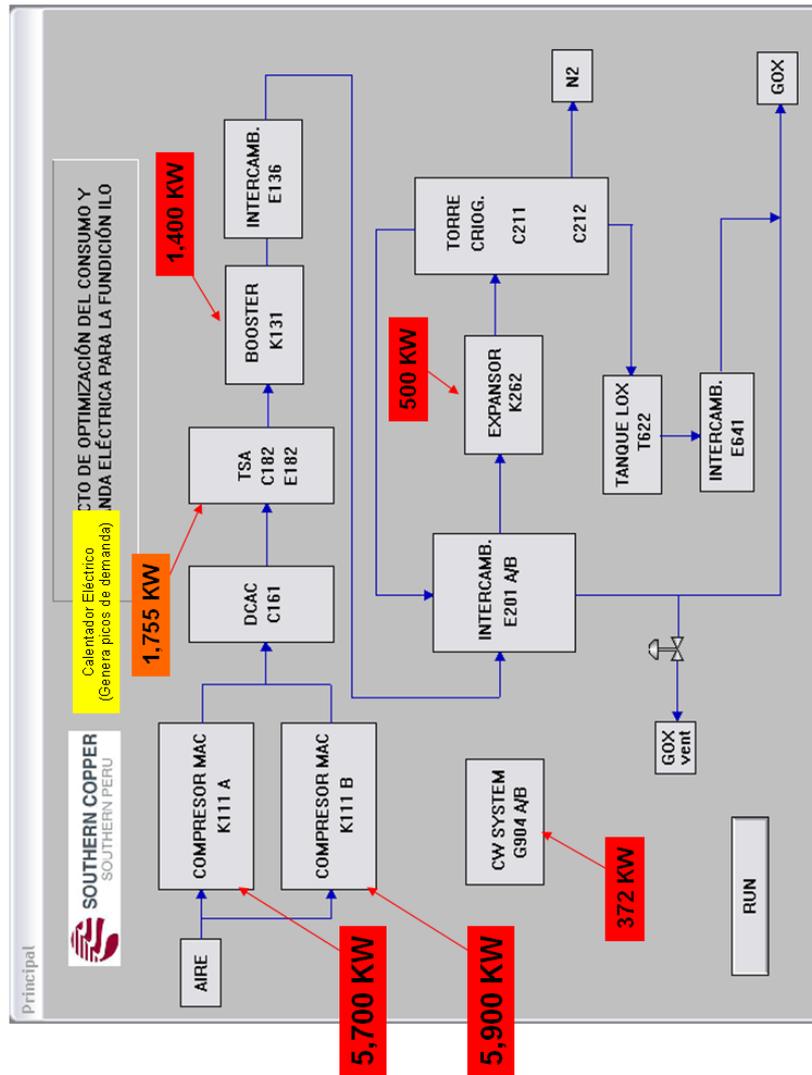


Figura 5.12
Diagrama de bloques inicial para la POX2
 Fuente: Planos PID y PFD. SCC. Elaboración: Propia

Este diagrama de bloques es general. Se toma como un esbozo del diagrama de bloques a realizar en la interfaz computacional en el software elegido.

En el acápite siguiente se observarán los pasos para el diseño de la interfaz, ya sea con un software propio, o por una aplicación externa.

5.4.2. Diseño de la interfaz

El diseño de la interfaz, depende del software usado y el diagrama realizado previamente, donde ya se definieron, las variables de entrada, salida e intermedias. Esta interfaz, va desde un muy simple diagrama de algoritmos, pasando por los diagramas de programación ladder, diagramas de bloque, o muy avanzadas interfaces gráficas.

En el caso de esta tesis, se recomienda utilizar los diagramas de bloques, debido a su facilidad de uso, su acoplamiento perfecto con el análisis de variables, y la gran variedad de softwares que presentan esta opción.

Uno de los puntos más importantes es que el software a usar permita la transcripción suave de los procesos y variables, tal como fueron definidos en la etapa del modelamiento. Para este fin se empleó el software Simulink de Mathworks, el cual fue comprado por la empresa en donde se realizó el caso práctico de la tesis.

La Figura 5.13, muestra la interfaz para el caso de la planta de oxígeno 2, que se viene realizando en esta tesis.

5.4.3. Especificaciones

Las especificaciones son muy importantes para establecer un punto de comparación entre lo que se está modelando, el diseño y la realidad.

En el caso de la planta de oxígeno 2, la planta está diseñada para proporcionar 1045 TM/D de oxígeno gaseoso (más flujo de impurezas) en las condiciones de diseño. La planta también será capaz de producir 20 TM/D de oxígeno líquido al operar a velocidades reducidas de producción de oxígeno gaseoso. El producto oxígeno se obtendrá por destilación criogénica. Las 1045 TM/D de oxígeno gaseoso se producirán a una presión de 207 kPa (manométrica).

Los flujos de producción de diseño se especifican en la Tabla 5.5, de acuerdo al fabricante.

Tabla 5.5
Especificaciones de producción de la planta de oxígeno

Producto	Unidades	MODO 4 (*2) Opera 2 MAC
Oxígeno Gaseoso	TM/D (*1)	1,045
Oxígeno Líquido	TM/D (*1)	0

Fuente: SCC

Mientras que las necesidades eléctricas, se presentan en la Tabla 5.6.

Tabla 5.6
Especificaciones de eléctricas de la planta de oxígeno

Garantía de Potencia según Diseño - MODO 1 de Operación	Potencia kW
MAC/BAC	12,076
Calefactor Regeneración de TSA (Promedio 24 horas)	200
Bombas de Agua para Enfriar	217
Generador Expander (crédito)	<u>(390)</u>
Potencia Total de la Planta	12,103

Fuente: SCC

5.5. VALIDACIÓN

5.5.1. Plan de pruebas

La metodología para realizar las pruebas, se realizó, al igual que en el caso de la predicción, considerando la disponibilidad de las fuentes, la facilidad de su acceso y la capacidad de manejo de bases de datos.

En el caso de una planta con sistema de supervisión e historización de datos, esta información es fácilmente accesible. En el sistema SCADA, se encuentran los todos los datos del proceso, necesarios para realizar una validación adecuada. El servidor Wonderware de la empresa tiene un manejo de datos mucho más versátil, ya que trabaja con bases de datos SQL, por lo que la toma de datos puede realizarse en cualquier momento.

Las pruebas se realizan, con una data tomada en un periodo de 48 horas de trabajo continuo, este horizonte varía de acuerdo a la planta y su capacidad de trabajar sin paradas programadas o no programadas. Para el caso de la Fundición de Ilo, el promedio indicado era de 2 días, ya que existía un patrón de parada de aproximadamente 3 días.

5.5.2. Contrastación de resultados

La contrastación de los resultados en una simulación es la etapa más importante de la misma, ya que si dichos resultados están fuera de las especificaciones, se deberá corregir el error en las condiciones de frontera, la estructura del modelo, las condiciones iniciales, o en el caso extremo, desechar el modelo seguido e iniciar desde cero.

En el caso de la Fundición de Ilo, el módulo de simulación final del sistema eléctrico, se muestra en la Figura 5.14.

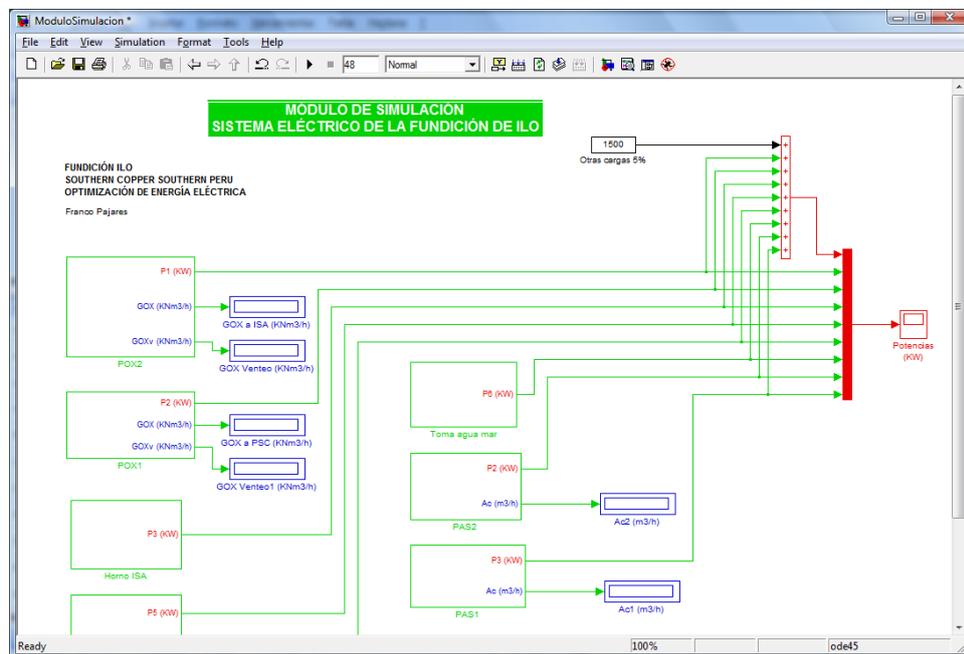


Figura 5.14
Módulo de simulación final del sistema eléctrico de la Fundición de Ilo
Fuente y elaboración: Propia

Esta pantalla muestra la configuración final del módulo de simulación, a través de la cual se contrastarán los resultados, y donde se presentarán las oportunidades de ahorro, mostrando su impacto, tanto a nivel eléctrico, como a nivel productivo.

Sin embargo, el caso que ha venido desarrollándose en esta parte de la tesis es el referido a la planta de oxígeno 2. En la Figura 5.15, se muestra la pantalla final del módulo de simulación de la planta de oxígeno 2, la cual constituye el componente más importante de la Fundición de Ilo.

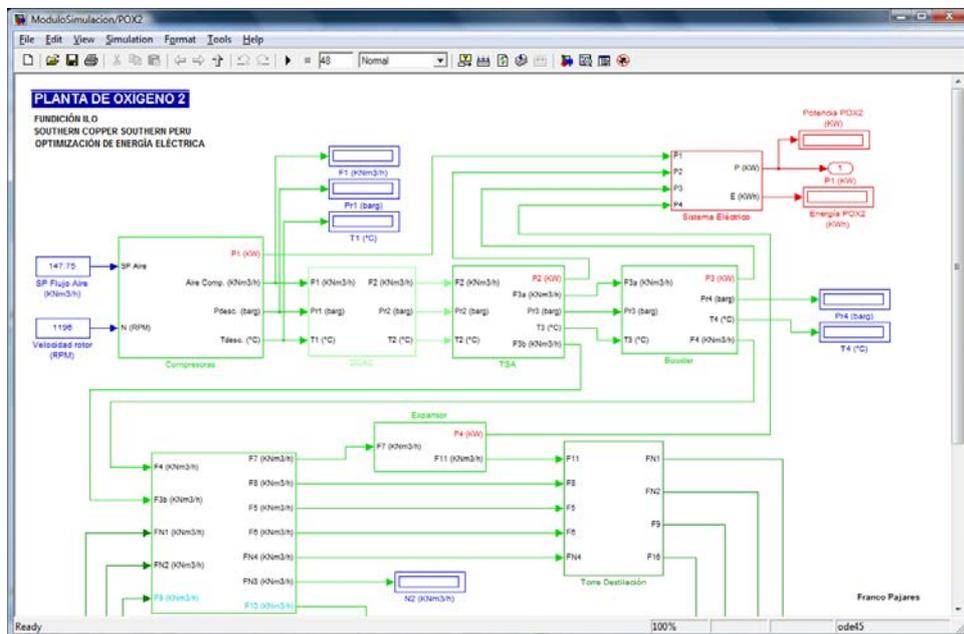
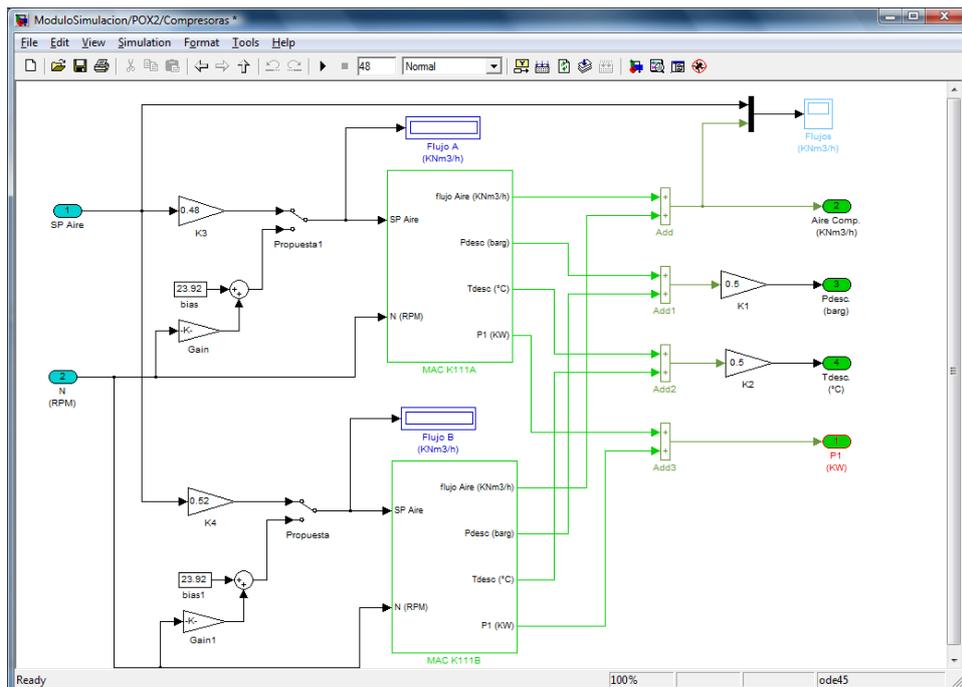


Figura 5.15
Módulo de simulación final del sistema eléctrico de la Planta de Oxígeno 2
 Fuente y elaboración: Propia

Como se observa, las diversas secciones de dicha planta están conectadas de acuerdo al diagrama de bloques desarrollado en el capítulo 5.4.1., los flujos de mayor relevancia están conectados entre sí, de tal manera

que de acuerdo a una entrada inicial, predefinida por las necesidades de producción, se puedan obtener los valores requeridos en la salida, tanto a nivel productivo, como eléctrico.

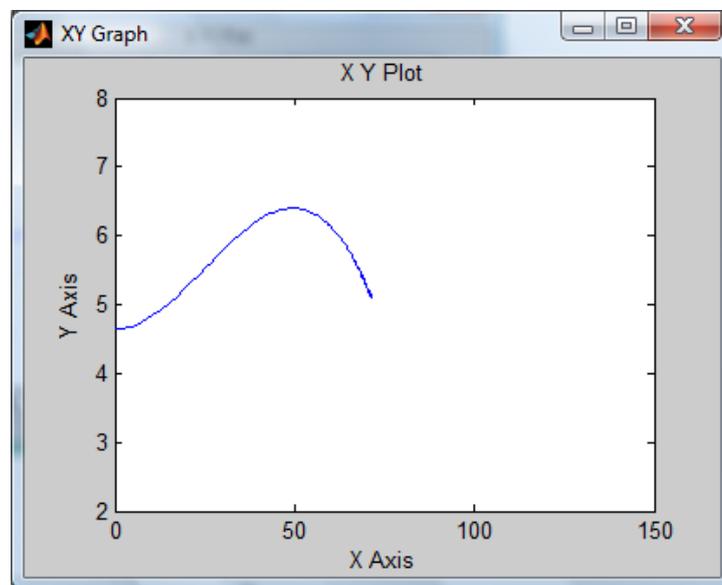
Las Figuras 5.16 (a), (b) y (c), muestran el modelo de los equipos más importantes, desde el punto de vista eléctrico, de la planta de oxígeno 2, y por tanto de la Fundición. Las compresoras MAC 111 A/B, están desarrolladas tanto en el nivel mecánico, como en el de control y el eléctrico. La simulación, permite observar cual es la evolución de variables de control, tales como el flujo de aire comprimido, la presión de compresión de salida, la posición de las válvulas, y principalmente el consumo de energía eléctrica.



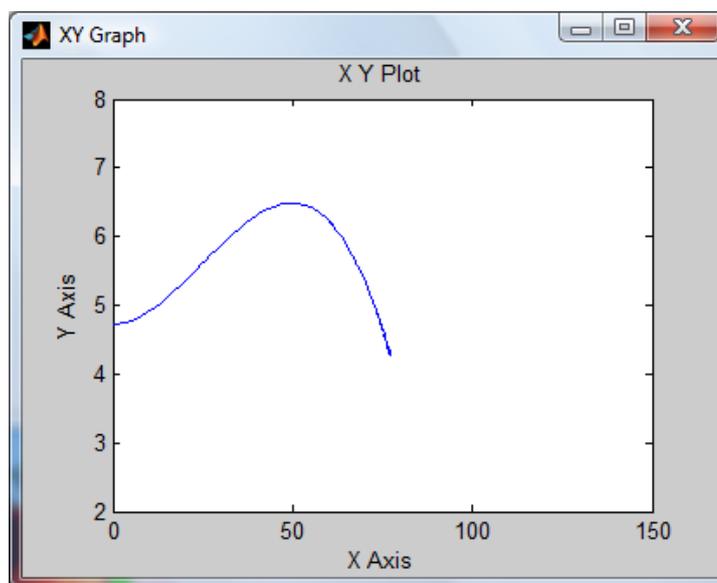
(a) Módulo de simulación de las compresoras de la planta de oxígeno 2

Con el modelo listo, se procede a correr la simulación, de tal manera que se puedan comparar los resultados obtenidos con los valores reales.

Las Figuras 5.17 (a) y (b), muestran las curvas flujo de aire comprimido versus presión de descarga de las compresoras A y B, respectivamente. Como se observa las curvas de simulación son las mismas que las estimadas en la Sección 5.3.5. Modelo matemático, en el cual se obtuvieron las ecuaciones necesarias para estas curvas.



**(a) Curva flujo volumétrico versus presión de descarga.
Compresora MAC 111 A**



**(b) Curva flujo volumétrico versus presión de descarga.
Compresora MAC 111 B**

Figura 5.17

Fuente y elaboración: Propia

La Figura 5.18, muestra los resultados de la simulación del sistema eléctrico de potencia, en donde la línea verde representa al total de la planta de oxígeno 2, mientras que las demás son las diferentes potencias consumidas en los equipos más importantes de la misma.

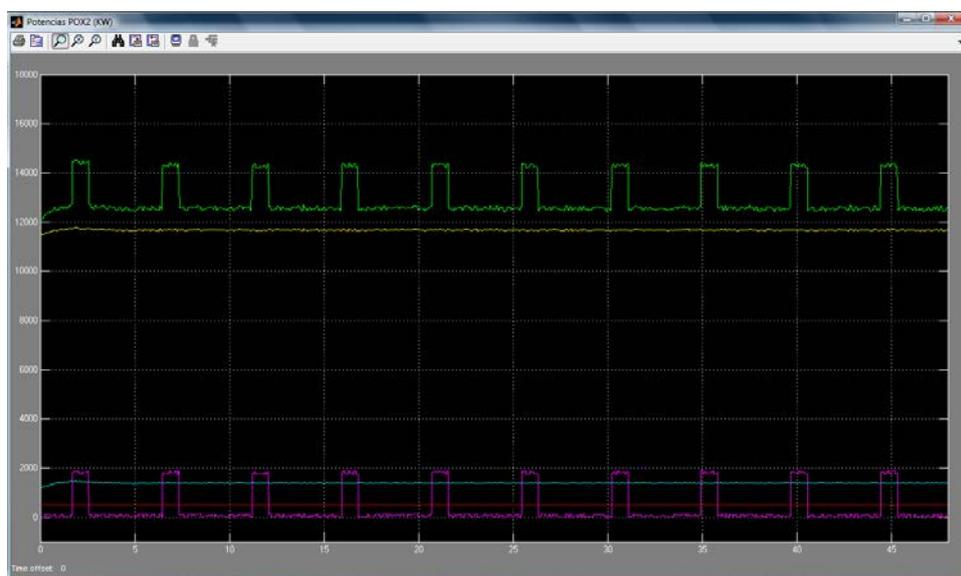


Figura 5.18
Resultados de la simulación. Potencias de la planta de oxígeno 2
Fuente y elaboración: Propia

La Figura 5.19, muestra la comparación entre los resultados de potencia simulados contra los datos reales, obtenidos del servidor de la empresa. Como se observa, la tendencia es la misma, existiendo pequeños retardos entre los picos de potencia, debido a la acción de los PLC en la realidad.

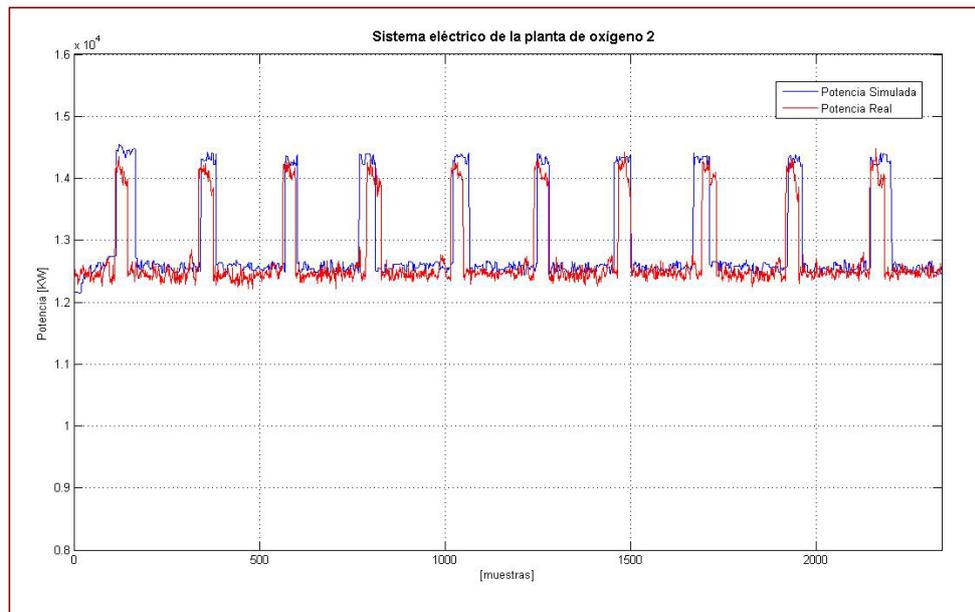


Figura 5.19
Contrastación de resultados de potencia en la planta de oxígeno 2
 Fuente y elaboración: Propia

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

$$\%e_{\text{rms}} = \frac{\sum_{i=1}^N \left(\frac{p_i - r_i}{r_i} \right)^2}{N} \times 100 \quad 5.21$$

Donde:

- p_i : Dato simulado
- r_i : Dato real
- N : Número de muestras

En la Tabla 5.7, se muestran los errores de simulación, y lo bien que aproxima el modelo simulado a la realidad, a nivel del sistema eléctrico.

Tabla 5.7
Error cuadrático medio del módulo de simulación

Fecha	%erms
23-Oct-07	0.1733%

Fuente y elaboración: Propia

Como se aprecia, el error en el sistema eléctrico es muy bajo, por lo cual se puede concluir que el modelo funciona correctamente para las variables de potencia y energía. Sin embargo, la segunda condición y el valor agregado de esta tesis radica en la posibilidad de observar las variables de producción, frente a cierto cambio en el sistema eléctrico. Y no sólo eso, sino que, además, se puede apreciar la dinámica de dichas variables indispensables para optimizar el control de las mismas.

La Figura 5.20, presenta las variables de proceso simuladas, las cuales son indispensables, ya que frente a cualquier mejora, éstas se deben mantener dentro de los rangos permitidos por el vendor.

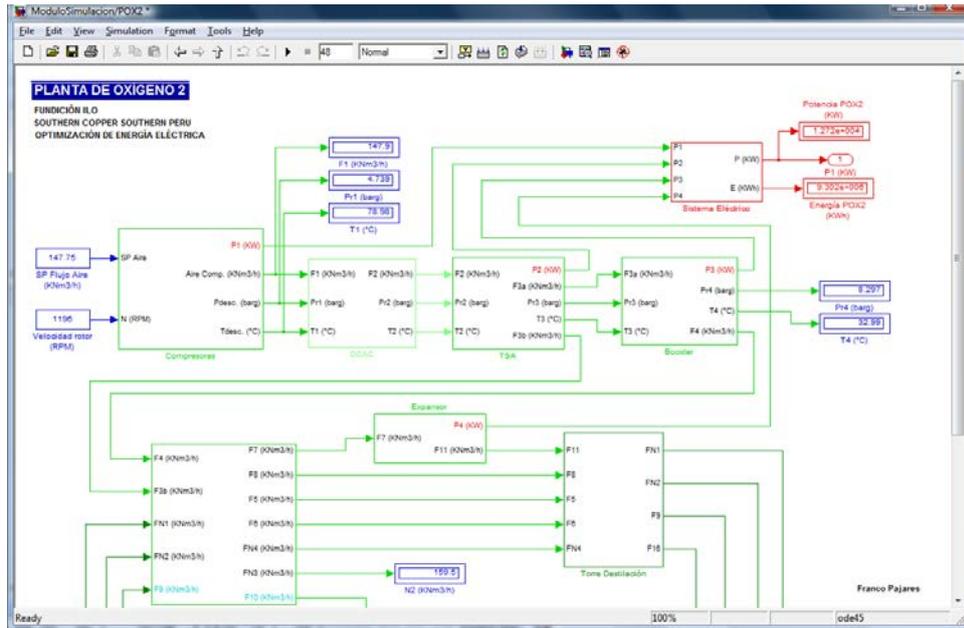


Figura 5.20
Variables de proceso de la planta de oxígeno 2, luego de la simulación
 Fuente y elaboración: Propia

En la Figura 5.21, se observan las 2 variables fundamentales del proceso de producción de oxígeno en la planta de oxígeno 2. El flujo volumétrico de oxígeno producido, y el oxígeno venteado. Los valores obtenidos son los mismos que los conseguidos en la realidad, para una producción de oxígeno de 32.78 KNm³/h y un venteo de 5.062 KNm³/h.

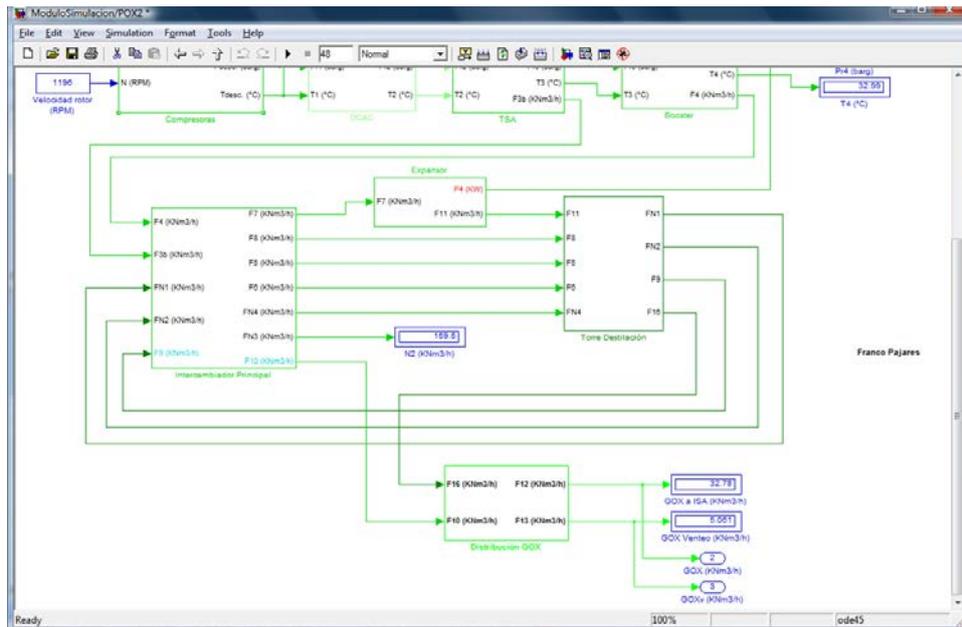


Figura 5.21
Variables de producción de la planta de oxígeno 2, luego de la simulación
Fuente y elaboración: Propia

Luego de integrar todas las plantas, finalmente para un escenario probable de producción, que puede ser modificado de acuerdo a los requerimientos de gerencia, en un periodo de 48 horas, se obtienen los resultados mostrados en la Figura 5.22.



Figura 5.22
Resultados de la simulación eléctrica de la Fundación de Ilo
Fuente y elaboración: Propia
Software: Simulink

En la Figura 5.23, se muestra finalmente el módulo de simulación de la Fundación de Ilo, donde las variables de proceso y eléctricas más importantes están integradas y simuladas en un solo diagrama.

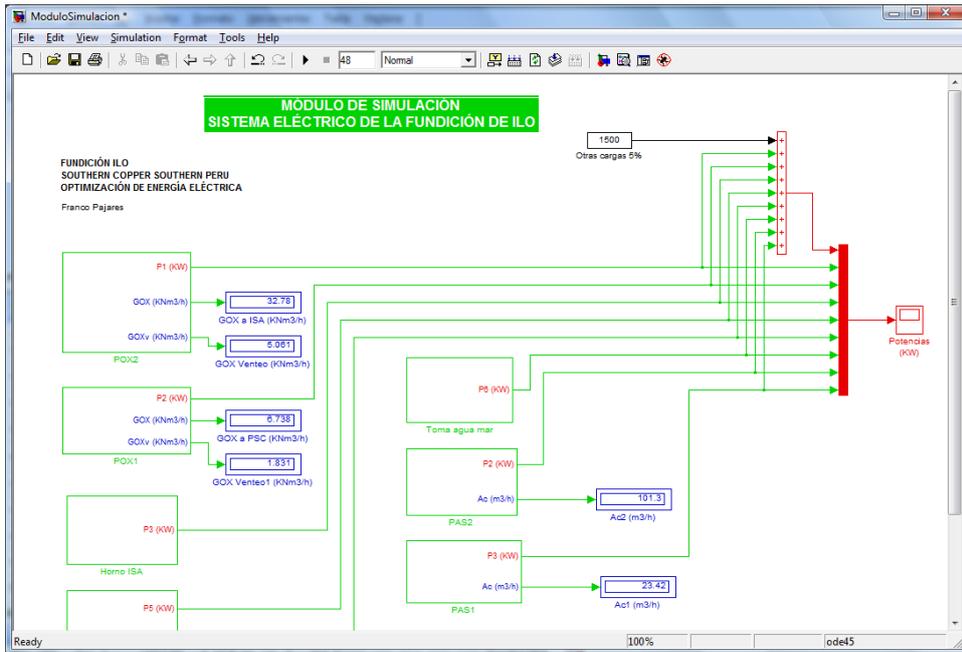


Figura 5.23
Módulo de simulación final de la Fundición de Ilo
Fuente y elaboración: Propia
Software: Simulink

CAPÍTULO 6

ANÁLISIS ECONÓMICO

El análisis económico es uno de los ítems más importantes en cualquier proyecto, tanto industrial como de investigación. Este análisis se debe realizar, para evaluar la posibilidad real o no de llevar a cabo la propuesta realizada, con el proyecto o la propuesta, analizando todos pros y contras que éste implicaría. Dentro del análisis que se debe realizar, se debe entender que cualquier tipo de recurso implica un costo, por lo cual se debe considerar la relación costo/beneficio aplicable a cada uno de los aspectos recomendados por cualquier metodología aplicable para proyectos. En el caso de esta tesis se está aplicando la metodología del PMI, en la cual se consideran como puntos más importantes en este análisis, el tiempo, el costo, los riesgos, los recursos humanos, la logística, las comunicaciones y la calidad. Dependiendo de cuán bien se obtengan los resultados, se procederá a iniciar el proyecto, y verificar sus alcances.

En la tesis, luego de desarrollar los módulos predictor y de simulación de la planta industrial, se procedió a plantear oportunidades de mejora, simulándolas y evaluando su impacto tanto a nivel de disminución de potencia eléctrica, así como a nivel de eficiencia de producción.

6.1. OPORTUNIDADES DE AHORRO

Una vez definidos y validados los módulos de predicción y simulación, se proceden a evaluar diversas oportunidades de ahorro energético. Para tal fin, se evalúan los puntos presentados en el capítulo I, es decir ubicar dónde se pueden presentar la mayor cantidad de energía desperdiciada. Hecho esto, se presentan una serie de propuestas de cambio de equipos, modificación de set points, o en un caso extremo reingeniería del proceso. Posteriormente, se procede a evaluar dichas oportunidades tanto en el módulo de predicción, como en el módulo de simulación. El módulo de simulación, permite visualizar de manera más profunda dichas mejoras, tanto a nivel energético, pero sobre todo a nivel del proceso, el cual es el punto clave de esta tesis, ya que muestra no sólo los posibles ahorros energéticos a lograr, sino sobre todo, el impacto de la mejora a nivel productivo o de proceso.

A continuación se muestra el análisis de las oportunidades y propuestas de ahorro energético, realizado para el caso de la planta de oxígeno 2, que se viene desarrollando en la tesis.

La principal oportunidad de ahorro se encuentra en la reducción de demanda eléctrica de las compresoras MAC K111. Para tal fin se han evaluado los parámetros de funcionamiento de estos equipos, como flujo de aire y presión de descarga.

En la Figura 6.1, se comparan las especificaciones de diseño de estas compresoras; es decir, flujo de aire de 72,248 Nm³/h, a presión atmosférica (0 KPag), y presión de descarga de 465 KPag respecto de sus valores de funcionamiento actuales, que se encuentran en 75,117 Nm³/h, a presión atmosférica, y presión de descarga de 5.65 bara (464 KPag). La curva de operación estándar de esta

compresora multietapa ha sido resaltada con color azul para ilustrar las condiciones de operación correctas.

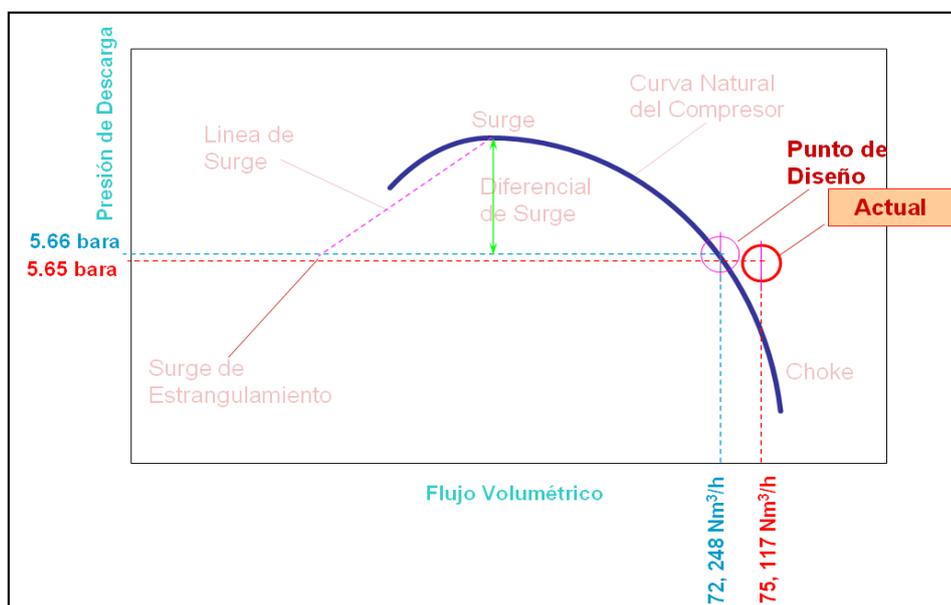


Figura 6.1
Comparación Diseño de las MAC vs. Operación Actual
Curva Característica: Presión – Flujo
Fuente: Curvas estándares para compresores. Compresores Ingersoll.
Elaboración: Propia

Esta situación se confirma con las lecturas de operación obtenidas del Active Factory (Figura 6.2), en el que aparecen ambas compresoras funcionando fuera del punto de operación recomendado: flujo volumétrico de 75,117 Nm³/h y una presión de descarga de 5.65 bara (464 KPag).

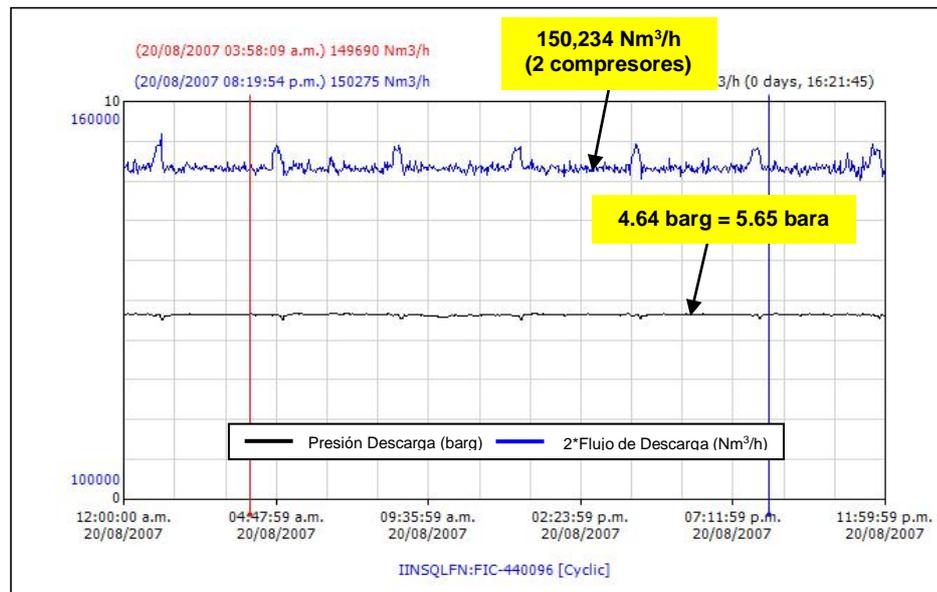


Figura 6.2
Condiciones Actuales de Presión de Descarga y
Flujo Volumétrico de las MAC
 Fuente: Active Factory (SCC)

Como se observa en la Figura 6.2, existe un sobreflujo volumétrico en los compresores de 2869 Nm³/h; sin embargo, la presión está acorde con los valores de diseño.

Propuesta 1

La primera propuesta consiste en corregir los lazos de control de la válvula de ingreso de alabes (IGV) de las compresoras MAC, para llevar el flujo y presión de descarga del aire a las condiciones de diseño, de tal manera que se aumente la eficiencia eléctrica del motor, disminuyendo las pérdidas mecánicas por fricción y calor. Esta modificación generará una disminución de la demanda de 91.75 KW por el compresor A y 282.83 KW por el compresor B, bajando el consumo de energía en 269,697 KWh, que representan US\$ 19,957 mensuales.

Las ecuaciones utilizadas son las siguientes:

$$\eta_e = \frac{\text{Pot}_m}{\text{Pot}_e} \quad 6.1$$

$$C = \frac{\text{Pot}_e}{\text{Pot}_{\text{enomin al}}} \times 100 \quad 6.2$$

$$\eta_e = -0.009C^2 + 1.18C \quad 6.3$$

$$\Delta\text{Pot}_m = \text{Pot}_e - \text{Pot}_m \quad 6.4$$

Donde:

η_e : Eficiencia eléctrica (%)

C : Carga del motor (%)

Pot_e : Potencia eléctrica real (5900 KW [MAC A] – 5700 KW [MAC B])

$\text{Pot}_{\text{enomin al}}$: Potencia eléctrica nominal (6000 KW)

Pot_m : Potencia mecánica o en el acople (KW)

ΔPot_m : Pérdidas mecánicas (KW)

Como ejemplo de cálculo de las pérdidas mecánicas para el compresor A, se tiene, en primer lugar, que la carga actual de los motores es:

$$C = \frac{5900}{6000} \times 100 = 98.33\%$$

Con este dato, se obtiene la eficiencia eléctrica de la ecuación 6.3

$$\eta_e = -0.009(98.3)^2 + 1.18(98.3) = 89.975\%$$

Con la eficiencia eléctrica, se consigue la potencia mecánica de la ecuación 6.1

$$\text{Pot}_m = \eta_e \times \text{Pot}_e = 0.8975 \times 5900 \text{KW}$$

$$\text{Pot}_m = 5308.54 \text{KW}$$

De la ecuación 6.4 se calcula las pérdidas mecánicas actuales:

$$\Delta \text{Pot}_m = 5900 - 5308.54$$

$$\Delta \text{Pot}_m = 591.48 \text{KW}$$

En la Tabla 6.1, se detallan los resultados de eficiencias y pérdidas mecánicas de los motores de las compresoras MAC A/B, durante el mes de agosto de 2007.

Tabla 6.1
Potencias y eficiencias eléctricas de los motores de los compresores de la POX2

	Pot_{real} (KW)	Pot_{nominal} (KW)	C (%)	n_e (%)	Pot_m (KW)	Pérdidas (KW)
K111 A	5900	6000	98.33	89.975	5308.525	591.475
K111 B	5700	6000	95.00	89.775	5117.175	582.825

Fuente: Datos de placa. Active Factory (Pot_{real} media agosto 2007)

Elaboración: Propia

Debido a que no se cuenta con las curvas características de las compresoras MAC en el manual del fabricante Cooper Compressors, se tomaron como referencia las curvas estándares de presión – flujo volumétrico y potencia en el acople – flujo volumétrico para compresoras centrífugas multietapas del fabricante Ingersoll.

Considerando una eficiencia eléctrica 91.5 % (eficiencia estándar para motores de inducción estándar) y tomando la potencia eléctrica real de la MAC A (5900 KW), se obtiene una potencia en el acople de diseño (nominal) aproximada de

5400 KW. La diferencia entre la potencia nominal y la potencia real en el acople, es energía perdida que se puede recuperar configurando adecuadamente los parámetros de los lazos de control.

En la Figura 6.3, se muestra la diferencia entre potencia de acople nominal (5400 KW) con la potencia de acople real (5309 KW), para la compresora MAC A, la cual es igual a 91 KW. En el caso del compresor MAC B, la diferencia es de 283 KW.

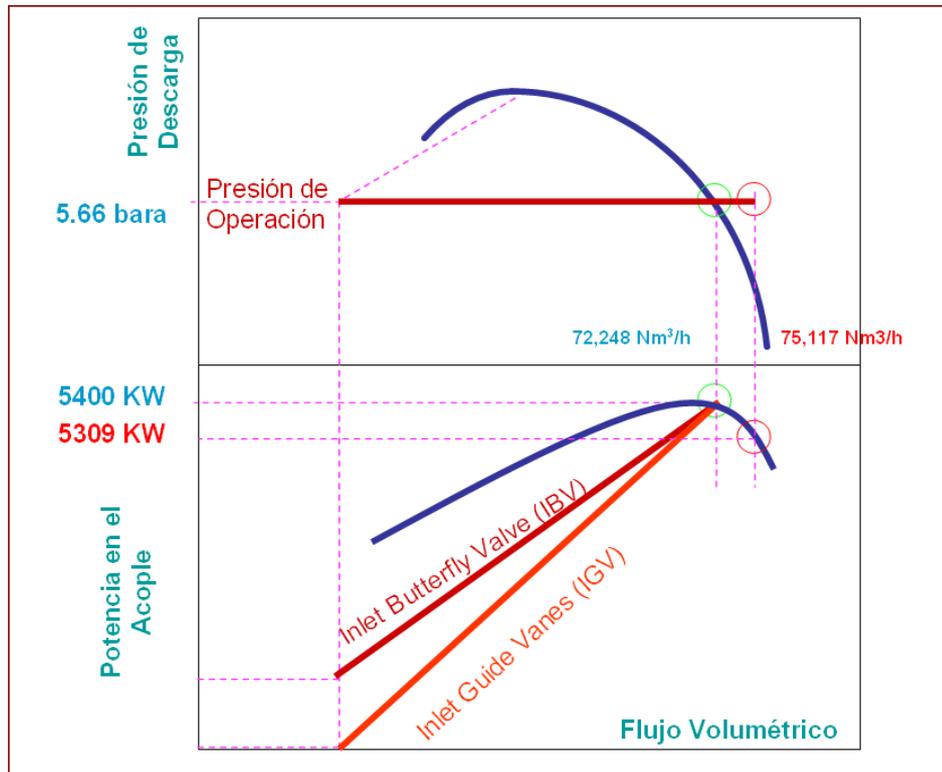


Figura 6.3
Condiciones actual y de diseño de las MAC.
Curvas características Presión – Flujo/Potencia Acople - Flujo
 Fuente: Curvas estándares para compresores. Compresores Ingersoll
 Elaboración: Propia

En la Tabla 6.2 se muestra el ahorro obtenido por la propuesta de ahorro 1.

Tabla 6.2
Condiciones actual y de diseño de las MAC

MAC	Ahorro (KW)	Ahorro (KWh)	Ahorro (US\$) D.Adicional	Ahorro (US\$) E.Adicional	Ahorro Total (US\$)
K111 A	91	65,520	691	4,848	5,540
K111 B	283	203,760	2,150	15,078	17,229
Total	374	269,280	2,842	19,927	22,769

Fuente y elaboración: Propia

Por tanto al aumentar la potencia mecánica del eje del compresor aumenta la eficiencia eléctrica, reduciendo las pérdidas mecánicas por fricción, aumentando la vida útil del equipo y disminuyendo costos por mantenimiento.

Propuestas 2 y 3

Cambiar el método de regulación de flujo de aire en las compresoras MAC K111 A/B, pasando del uso de las válvulas de ingreso de alabes (IGV) a la utilización de variadores de velocidad en los motores de inducción D111 A/B.

Actualmente la demanda de oxígeno es intermitente y depende de la disponibilidad del horno ISA, tal como se muestra en la Figura 6.4. Sin embargo, la producción de oxígeno sigue estando en sus niveles máximos no habiendo la posibilidad de regulación de este flujo, como se ve en las líneas verticales roja y azul del mismo gráfico, donde a pesar que el requerimiento en la lanza del ISA sea nulo, la producción sigue estando en sus niveles máximos de 31,145 Nm³/h de oxígeno al 95% de pureza.

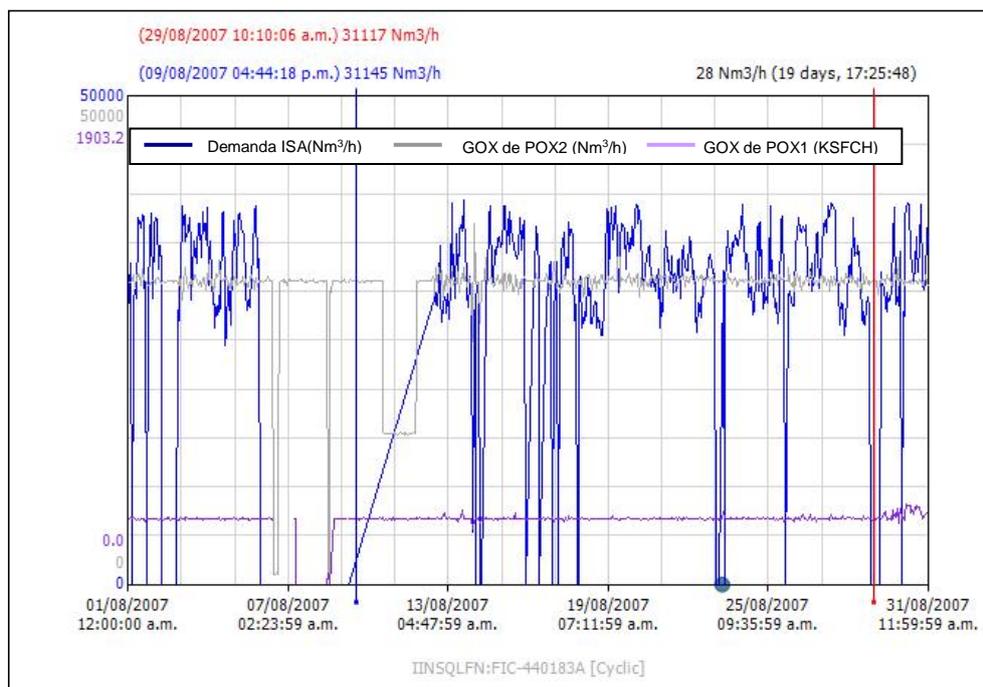


Figura 6.4
Balance de Oxígeno de la Fundición Ilo. Mes de agosto del 2007
 Fuente: Active Factory (SCC). Elaboración: Propia

Las razones de la continuidad en la operación de la POX2, se dan debido a la dificultad de puesta en marcha ya que se trabaja con temperaturas de criogenización, motivo por el cual sólo se la apaga en períodos grandes de parada de producción (ref. 07/08/07 – 12/08/07, Figura 6.4).

La regulación apropiada a través de la válvula IGV, puede ser una alternativa de disminución de flujo, sin embargo la potencia del motor no disminuiría en gran medida, ya que el sistema seguiría trabajando a su velocidad nominal de 1180 RPM.

En la regulación por variadores de velocidad, el flujo se controla a través del cambio en la velocidad nominal del motor de inducción trifásico por medio de un driver de potencia, que modula la velocidad de giro del eje, dependiendo de la

demanda real de aire comprimido que se necesite en ese momento. En la Figura 6.5, se muestra el lazo de control a utilizar.

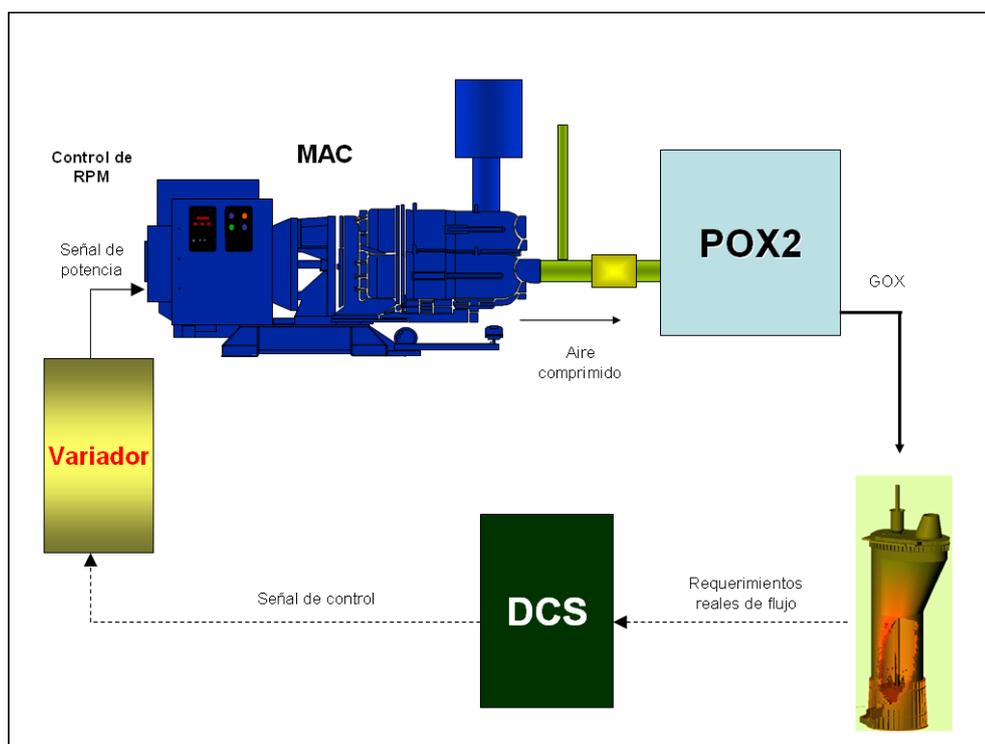


Figura 6.5
Lazo de Control de las MAC utilizando Variadores de Velocidad
 Fuente y elaboración: Propia

Si se usan variadores de velocidad, manteniendo las recomendaciones de diseño y de apertura de los alabes de la IGV (entre 40° y 60°) constantes, para regular el flujo, la demanda disminuiría 27.1% sólo al regular el flujo a 10% menos de su valor actual, para períodos de parada de producción, o cuando la demanda de oxígeno en el horno ISA sea muy baja.

Si en cambio, el flujo se regula al 50%, el ahorro por demanda (y por ende de energía) será de 87.5%. Teniendo en cuenta las condiciones de surge (intento de retorno del aire, debido a flujos muy bajos y presiones muy altas), es recomendable realizar la disminución del volumen, sólo hasta un 20%. En la Figura 6.6, se muestra

la curva flujo versus potencia, a través de regulación de velocidad de giro. Se nota claramente la disminución tanto en demanda como en consumo, lográndose un ahorro de US\$ 85,198 por compresor, sólo por concepto de energía.

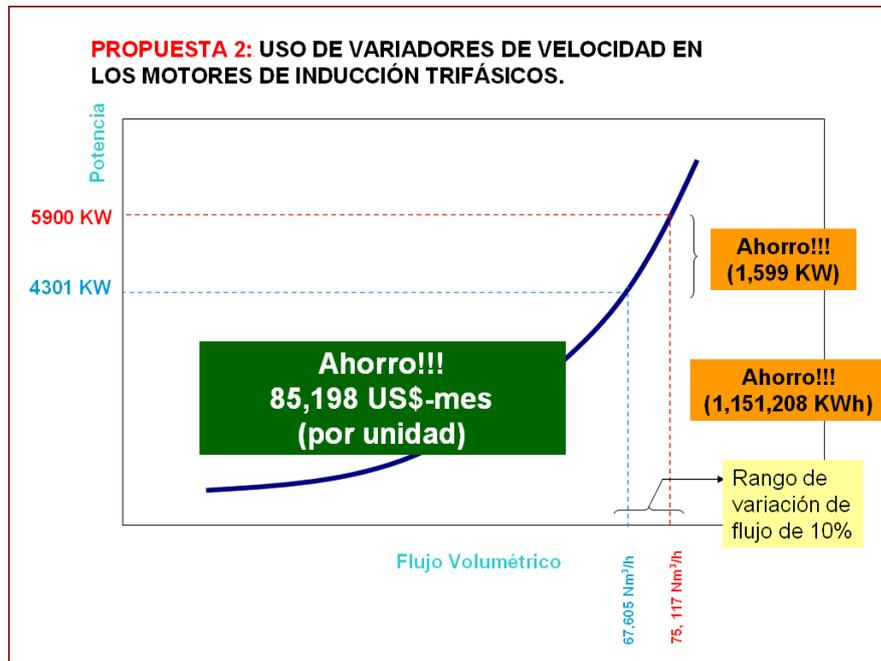


Figura 6.6
Curva Potencia – Flujo Volumétrico de compresores usando regulación por variadores de velocidad
 Elaboración: Propia

Las ecuaciones usadas se basan en las leyes de semejanza para turbomáquinas centrífugas, en donde se dice que teniendo un impulsor de diámetro constante, la potencia en el eje (KW) varía de manera proporcional al cubo de la velocidad en el mismo (RPM); y a su vez, el flujo volumétrico (Nm³/h) varía de manera proporcional a la velocidad (RPM).

$$\frac{Pot_{m_1}}{Pot_{m_2}} = \left(\frac{N_1}{N_2} \right)^3 \tag{6.5}$$

$$\frac{N_1}{N_2} = \frac{Q_1}{Q_2} \quad 6.6$$

Donde:

Pot_m : Potencia mecánica o en el eje (KW)

N : Velocidad de giro (RPM)

Q : Flujo volumétrico (Nm³/h)

Como ejemplo de cálculo para una disminución del 10% en el flujo volumétrico, es decir de Q₂ = 75,117 Nm³/h a Q₁ = 67,605 Nm³/h, se tiene la siguiente disminución de potencia.

De las ecuaciones 6.5 y 6.6, se observa que:

$$\frac{\text{Pot}_{m_1}}{\text{Pot}_{m_2}} = \left(\frac{Q_1}{Q_2} \right)^3 = \left(\frac{67,605 \text{ Nm}^3/\text{h}}{75,117 \text{ Nm}^3/\text{h}} \right)^3$$

Considerando la potencia real de operación en el eje igual a 5900 KW (eficiencia eléctrica de 1), apreciado en le gráfico 6.6, entonces la nueva potencia consumida será de:

$$\text{Pot}_{m_1} = 5,900\text{KW} \times \left(\frac{67,605 \text{ Nm}^3/\text{h}}{75,117 \text{ Nm}^3/\text{h}} \right)^3$$

$$\text{Pot}_{m_1} = 4,301.1\text{KW}$$

Por lo tanto, el ahorro en KW será de:

$$\Delta\text{Pot} = \text{Pot}_{m_2} - \text{Pot}_{m_1}$$

$$\Delta\text{Pot} = 1,598.9\text{KW}$$

Lo cual representa un ahorro mensual de energía en KWh de:

$$\Delta E = 1,598.9 \text{KW} \times 30 \frac{\text{días}}{\text{mes}} \times 24 \frac{\text{h}}{\text{día}}$$

$$\Delta E = 1,151,208 \text{KWh}$$

Considerando la razón de energía estable en 0.074 US\$/KWh, el ahorro económico sólo por concepto de energía, será de:

$$\text{AhorroE} = 1,151,208 \text{KWh} \times 0.074 \frac{\text{US\$}}{\text{KWh}}$$

$$\text{AhorroE} = 85,189.39 \text{US\$}$$

En las Tablas 6.3 y 6.4, se muestran las relaciones entre disminución de flujo y disminución de potencia, así como los ahorros respectivos en KW, KWh y dólares, por cada compresor.

Tabla 6.3
Ahorros usando regulación de flujo a través de variadores de velocidad en US\$ por mes. Compresor MAC K111 A

	%dismin flujo	%dismin potencia	Ahorro (KW)	Ahorro (KWh)	Ahorro (US\$) D.Adicional	Ahorro (US\$) E.Adicional	Ahorro Total (US\$)
Recomendada	5	14.26	841	605,871	6,394	44,834	51,228
	10	27.10	1,599	1,151,208	12,149	85,189	97,339
	15	38.59	2,277	1,639,197	17,299	121,301	138,600
	20	48.80	2,879	2,073,024	21,878	153,404	175,281
Surge	30	65.70	3,876	2,790,936	29,454	206,529	235,983
	40	78.40	4,626	3,330,432	35,148	246,452	281,600
	50	87.50	5,163	3,717,000	39,227	275,058	314,285

Elaboración: Propia

Tabla 6.4
Ahorros usando regulación de flujo a través de variadores de velocidad en US\$ por mes. Compresor MAC K111 B

	%dismin flujo	%dismin potencia	Ahorro (KW)	Ahorro (KWh)	Ahorro (US\$) D.Adicional	Ahorro (US\$) E.Adicional	Ahorro Total (US\$)
Recomendada	5	14.26	813	585,333	6,177	43,315	49,492
	10	27.10	1,545	1,112,184	11,737	82,302	94,039
	15	38.59	2,199	1,583,631	16,713	117,189	133,901
	20	48.80	2,782	2,002,752	21,136	148,204	169,340
Surge	30	65.70	3,745	2,696,328	28,456	199,528	227,984
	40	78.40	4,469	3,217,536	33,956	238,098	272,054
	50	87.50	4,988	3,591,000	37,898	265,734	303,632

Elaboración: Propia

Al realizar una disminución de 10% en el flujo de los compresores, utilizando regulación de velocidad del motor, se obtendrá un ahorro medio de US\$ 95,688.83 mensual por compresor, lo que hace un total de US\$ 191,377.65. Este ahorro es inmediato y se nota directamente en la facturación y sus pagos.

En la Tabla 6.5 se muestra el total de ahorro mensual por demanda y energía adicional usando regulación por variadores de velocidad de los compresores MAC A y B.

Tabla 6.5
Ahorros mediante disminución de flujo a través de variadores de velocidad en US\$
por mes. Total mensual

	%dismin. flujo	Ahorro (US\$) MAC A	Ahorro (US\$) MAC B	Ahorro (US\$) Total
Recomendada	5	51,228	49,492	100,720
	10	97,339	94,039	191,378
	15	138,600	133,901	272,501
	20	175,281	169,340	344,621
Surge	30	235,983	227,984	463,967
	40	281,600	272,054	553,653
	50	314,285	303,632	617,917

Elaboración: Propia

El ahorro esperado por la disminución del 10% de flujo en los compresores MAC A/B representa un estimado mensual de *US\$ 191,378*. Estos ahorros pueden ser aún superiores si consideramos la influencia de las disminuciones de flujo en el resto de equipos de la planta, tales como el Booster, las bombas de agua de enfriamiento o el calefactor del TSA.

El estudio realizado hasta el momento, es aplicable a todas las demás áreas donde se utilicen turbomáquinas, tales como bombas centrífugas, sopladores o ventiladores. El potencial de ahorro es muy grande, dependiendo de las necesidades específicas de cada sistema. Los estudios técnicos para las demás plantas, fueron realizados por el resto de equipo del proyecto. Su factibilidad de ahorro, se evaluó tanto a nivel eléctrico como a nivel procesos.

6.2. EVALUACIÓN ECONÓMICA

Para la realización de una evaluación económica se requiere que haya sido posible identificar beneficios y costos asociados al proyecto, y que dichos beneficios o costos, o sus componentes más importantes, puedan ser expresados en términos cuantitativos valorizables en unidades de valor comparables. De esta manera el perfil constituirá el resumen de los beneficios netos expresados en términos monetarios en cada período. Si los beneficios y/o los costos no pueden ser medidos en términos monetarios no será posible emplear el esquema tradicional de la evaluación económica de proyectos.

En esta etapa de evaluación se procede a seleccionar y calcular los indicadores para decisiones de inversión apropiados tales como el valor actualizado de los beneficios netos (VAN), la tasa interna de retorno del proyecto (TIR), o el costo uniforme equivalente anual (CUEA), entre otros, se somete los indicadores calculados a un análisis de riesgo e incertidumbre utilizando alguna técnica como la sensibilización, y se procede a la actividad final de cada iteración que es la conclusión.

A continuación se muestra el ejemplo de la evaluación económica realizada en el caso que se viene desarrollando en la tesis.

En la Tabla 6.6, se muestra el resumen de propuestas de ahorro de energía eléctrica para la Fundición de Ilo, por cada planta analizada, que conllevan a una reducción de la demanda promedio de **5,045 KW** y una disminución del consumo de energía eléctrica mensual de **3,644,352 KWh**, generando un ahorro económico en la facturación por los cargos de demanda y consumo adicionales, estimado en **US\$ 308,018** mensuales.

Tabla 6.6
Ahorros totales en la fundición de Ilo US\$ por mes

Nº	PLANTA	PROPUESTA	Reducción demanda promedio (KW)	Reducción Consumo mensual (KWH)	Ahorro por cargo de demanda adicional (7.5985\$/KW)	Ahorro por cargo de energía adicional (0.074\$/KWh)	AHORRO TOTAL US\$
1	POX2	Seteo y ajuste de las válvulas IGV de las compresoras MAC a condiciones de diseño	374	269,280	2,842	19,927	22,769
2	POX2	Regulación de flujo por variadores de velocidad en la compresora MAC K111 A	1,599	1,151,280	12,150	85,195	97,345
3	POX2	Regulación de flujo por variadores de velocidad en la compresora MAC K111 B	1,545	1,112,400	11,740	82,318	94,057
4	PAS2	Regulación de flujo por variadores de velocidad en el Blower A	713	513,360	5,418	37,989	43,406
5	PAS2	Regulación de flujo por variadores de velocidad en el Blower B	703	506,160	5,342	37,456	42,798
6	PAS2	Apagado automático de bombas, ventiladores y sopladores en días de producción nula	(166*)	11,952	0	884	884
6	Agua de Mar	Cambiar 3 bombas de agua de 933 KW por 6 bombas de 490 KW	111	79,920	843	5,914	6,758
TOTAL MENSUAL			5,045	3,644,352	38,335	269,683	308,018

Elaboración: Propia

Ahorro Mensual por Demanda Adicional

La disminución de demanda adicional media estimada es de 5,045 KW, que representa un ahorro económico por demanda adicional de:

$$\text{AhorroP} = P \times \text{CR1} = 5,045 \text{KW} \times 7.5985 \frac{\text{US\$}}{\text{KW}}$$

$$\text{AhorroP} = \text{US\$}38,335$$

Ahorro Mensual por Energía Adicional

El ahorro por energía adicional estimado es de:

$$E = P \times d \times h = 5,045 \text{KW} \times 30 \frac{\text{días}}{\text{mes}} \times 24 \frac{\text{h}}{\text{día}} + 11,952 \text{KWh}$$

$$E = 3,644,352 \text{KWh}$$

Lo cual representa un ahorro económico de:

$$\text{AhorroE} = E \times \text{ER} = 3,644,352 \text{KWh} \times 0.074 \frac{\text{US\$}}{\text{KWh}}$$

$$\text{AhorroE} = 269,683 \text{US\$}$$

Por lo tanto el ahorro mensual total estimado, será de:

$$\text{Ahorro} = \text{AhorroE} + \text{AhorroP}$$

$$\text{Ahorro} = 308,018 \text{US\$}$$

Donde:

- E : Energía consumida mensual (KWh)
- P : Potencia media demandada mensual (KW)
- ERA : Razón de energía adicional (0.074 US\$/KWh)
- CR1 : Razón de capacidad adicional (7.5985 US\$/KW)

6.2.1. Flujo de caja económico

Si se realiza el análisis de Flujo de Caja Económico trimestral y considerando una inversión por los variadores de velocidad de US\$ 2 millones se obtendrá que el Proyecto es viable. La tasa de descuento utilizada, es la solicitada por Southern e igual a 15% anual, que equivale a 3.6% trimestral, con lo cual se obtiene un VAN a 5 años (20 trimestres) de US\$ 1.52 millones. Es decir que aparte de recuperar la inversión inicial, cubrir los costos (incluida la depreciación), y obtener una ganancia de 15% anual, se obtendrá US\$ 1.52 millones. La Figura 6.7 muestra el Flujo de Caja Económico empleado para el proyecto.

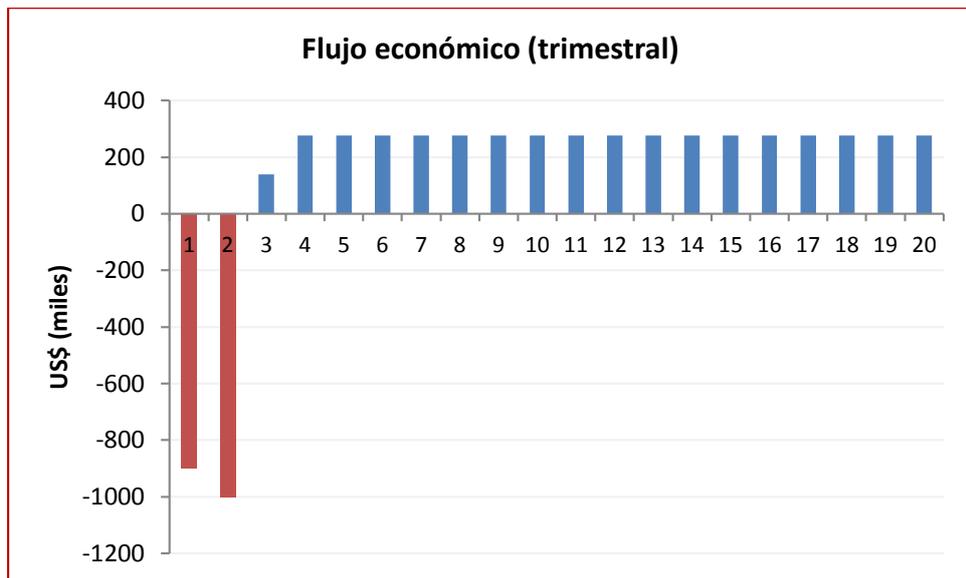


Figura 6.7
Flujo de caja económico. Proyecto Optimización Energía Ilo
 Elaboración: Propia

Si se calcula el proyecto con ahorros a perpetuidad, se obtendrá un VAN mucho mayor e igual a US\$ 5.396 millones. Este hecho hace que el proyecto a largo plazo sea aún mucho más viable.

Si el proyecto se calcula bajo $VAN = 0$; es decir, es viable sin ninguna ganancia adicional, el tiempo de recuperación de la inversión sería de 2 años, lo cual es bastante aceptable para un proyecto minero.

6.3. PRUEBAS Y RESULTADOS

Durante fines del 2007 y principios del 2008, se empezaron a aplicar las mejoras en la regulación de las válvulas IGV de las compresoras de la POX2.

Las pruebas consistían en 2 puntos fundamentales:

- Cuando la planta paraba, el operador empezó a disminuir el flujo de producción de oxígeno, aplicando las rampas de bajada recomendadas por el fabricante, lo cual originaba un cierre gradual y controlado de las IGV de las compresoras MAC A/B de la POX2. De esta manera, mientras el horno estuviera detenido, la planta de oxígeno, seguiría operativa, pero consumiendo la mínima cantidad de energía posible.
- Debido a un problema operativo en los **intercoolers**, se fueron disminuyendo paulatinamente los SP de apertura de las válvulas IGV de las compresoras, de esta manera a pesar que se disminuyó la producción de GOX hasta 950 TPD, se logró disminuir en gran medida la potencia de cada compresor.

La Figura 6.8, muestra el ahorro obtenido en el compresor A, mientras que la Figura 6.9 muestra el ahorro conseguido en el compresor B, desde el 1 de enero al 27 de noviembre del 2008.

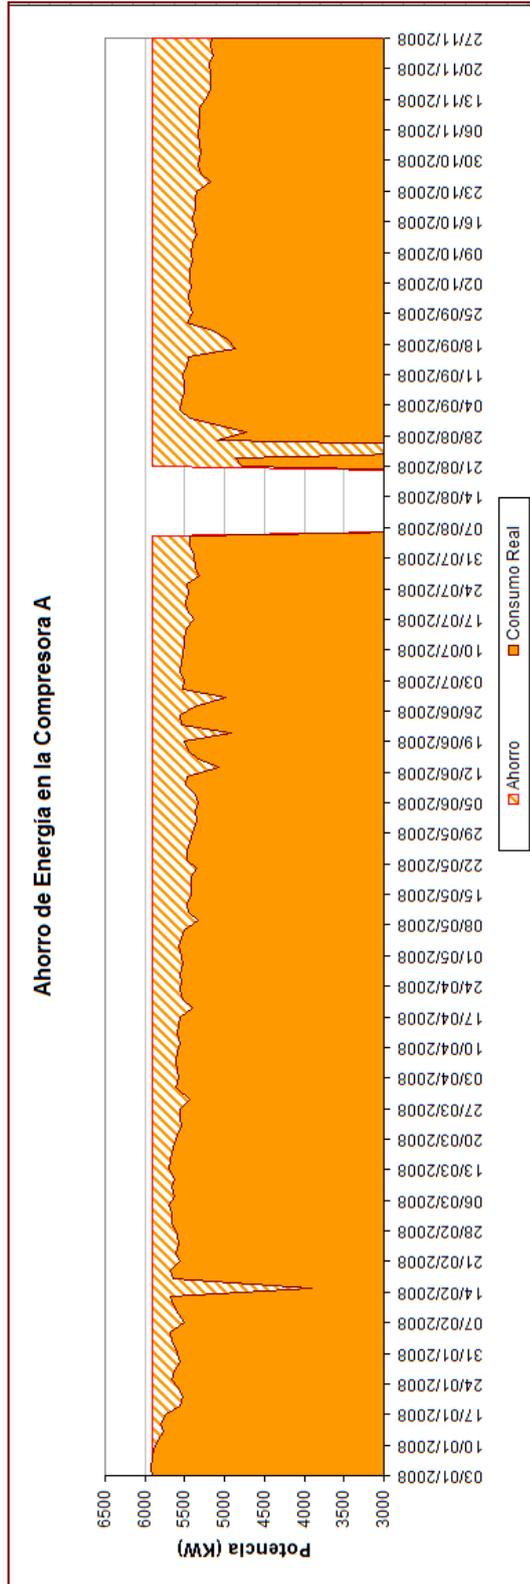


Figura 6.8 Ahorros durante el 2008. POX2. MAC 111 A

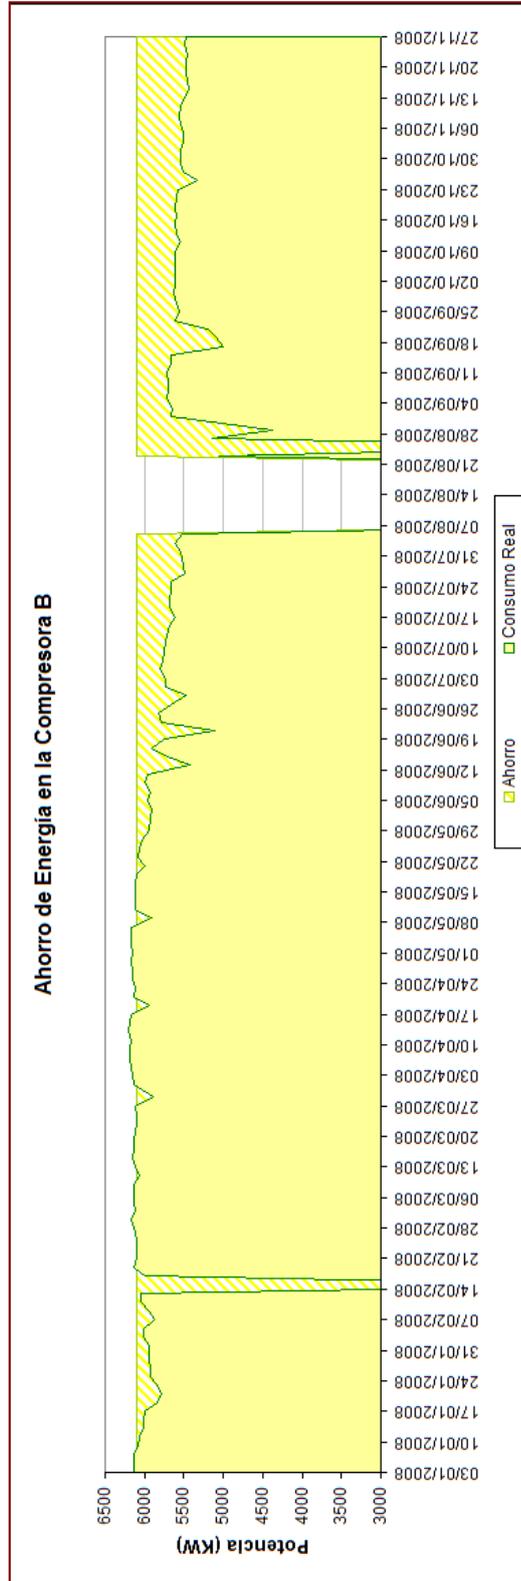


Figura 6.9 Ahorros durante el 2008. POX2. MAC 111 B

Los resultados reales obtenidos hasta noviembre del 2008 por la propuesta 1, son los siguientes:

N°	PLANTA	PROPUESTA APLICADA	Reducción de demanda promedio (KW)	Reducción de consumo 2008 (KWh)	Ahorro por cargo de demanda adicional (7.5985 U \$\$/KW)	Ahorro por cargo de energía adicional (0.080 U \$\$/KWh)	AHORRO TOTAL (US\$)
1	POX 2	Seteo y ajuste de las válvulas IGV de la compresora MAC K111 A. Utilización de las rampas de bajada en parada de producción de la compresora MAC K111 A	464	3,541,797	3,526	283,344	286,869
2	POX 2	Seteo y ajuste de las válvulas IGV de la compresora MAC K111 B. Utilización de las rampas de bajada en parada de producción de la compresora MAC K111 B	347	2,626,572	2,637	210,126	212,762
TOTAL 2008			811	6,168,369	6,162	493,470	499,632
TOTAL MENSUAL			-	560,761	560	44,861	45,421

Como se observa existe un ahorro real de US\$ 499,632 durante el 2008, lo cual indica el éxito de las propuestas planteadas para el caso específico presentado en este informe. La tesis; por lo tanto, comprueba que de la aplicación de modelos de predicción mediante redes neuronales y modelos de simulación dinámica, son herramientas competentes para obtener un beneficio directo en la optimización energética.

CONCLUSIONES

De acuerdo al análisis, evolución y resultados de la presente tesis, y estando en concordancia con el objetivo general y los objetivos específicos, se llegó a las siguientes conclusiones:

1. El rigor en el manejo de la información ha permitido la aplicación en el diseño, construcción y validación de los modelos predictivo y de simulación, facilitando el uso de herramientas que ayudan a la optimización de la demanda de potencia y consumo de energía eléctrica, tanto para el caso general como para el específico en una planta industrial.
2. El modelo predictivo facilita la planificación de la demanda de energía eléctrica, debido a su potencia en el pronóstico de la evolución horaria de la energía eléctrica, haciendo posible, más adelante, implementar un control de demanda, automático que permita eliminar los picos que producen multas en la facturación o desgastes innecesarios en las líneas eléctricas. En el caso de aplicación práctica, es decir, la predicción de consumo y demanda la Fundación de Ilo, mediante redes neuronales dinámicas recurrentes, se consiguió un error cuadrático medio mensual menor de 1%.

3. El módulo de simulación permitió integrar los subsistemas más importantes dentro del proceso de industrial, como son: el eléctrico, el mecánico, el de instrumentación y el energético, de tal manera que se pudieron ensayar diversos escenarios de operación y control, y evaluar su impacto en todos los subsistemas mencionados, sin los costos y riesgos que una parada de planta implicaría.

4. Es posible reducir el consumo de energía eléctrica de la una planta industrial en aproximadamente 10%, al disminuir los cargos de demanda y consumo de energía eléctrica. En el caso de la Fundición de Ilo se presentaron una serie de propuestas de ahorro energético que constituyen un aproximado de US\$ 308,000 de ahorro mensual. Además durante el 2008 el ahorro obtenido, debido a la aplicación de las propuestas fue de US\$ 499,622 desde enero hasta noviembre del mismo año.

RECOMENDACIONES PARA TRABAJO FUTURO

Se sugiere como recomendaciones para el trabajo futuro, y de acuerdo a cada ítem, lo siguiente:

1. Para el módulo de predicción, se deberán tratar nuevas metodologías para la predicción de series temporales muy grandes. En el caso de la presente tesis, se utilizaron redes neuronales dinámicas recurrentes; sin embargo, de acuerdo a la bibliografía presentada, existen numerosos métodos para tratar el tema. Además de acuerdo a la libertad que presentan las redes neuronales para establecer arquitecturas particulares en cada caso particular, habrían muchas posibilidades para temas de investigación. El trabajo futuro también implicaría, la aplicación de este sistema en un procesador independiente de la PC o un software de simulación, de tal manera que pueda servir para su comercialización.
2. Respecto al módulo de simulación, queda como trabajo futuro, el análisis a profundidad de las no linealidades en el caso de los procesos termodinámicos y químicos, así como su influencia en el consumo de energía eléctrica. Los modelos de simulación, además permitirán integrar de manera automática las

variaciones de parámetros del proceso, no sólo en función de los requerimientos de producción, sino también de acuerdo a las necesidades de menor consumo energético.

3. Con respecto a la metodología, se pueden realizar diversos aportes a las técnicas ya existentes para el ahorro de energía eléctrica; sin embargo, se deberá tener presente que las metodologías actuales están en cierta medida estandarizadas. Por tal motivo, la nueva metodología empleada tiene que acercarse a los lineamientos de los organismos internacionales, así como al caso particular de cada industria.

ANEXOS

ANEXO 1 Principales equipos de la Fundición de Ilo

N°	Plantas	Centros de Consumo	Medidor	Equipo o Grupo de equipos
1	Plantas de Oxígeno	Planta de oxígeno 2	I513	Alimentación Principal
			I1000	Línea de llegada a la barra
			I1002	Main air compressor D111B
			I1003	Main air compressor D111A 8046HP
			I1001	Transformer MIF-1 PR1 2500kVA 13.8/4.16kV
			I1004	Transformer 2500kVA 13.8/0.48kV
		Planta de oxígeno 1	I204	AREA 70 Planta de oxígeno 1 Gral.
			I208	Planta de oxígeno 1 Gral.
2	Plantas de Ácido	Planta de ácido 2	I502	Alimentación Principal
			I2000	Línea de llegada a la barra
			I2001	BLOWER MAIN DRIVE #1
			I2002	BLOWER MAIN DRIVE #2
			I2003	TRANSFORMER 5000KVA 13.8/4.16kV
		I2004	TRANSFORMER 2500KVA 13.8/0.48kV	
		Planta de ácido1	I209	Planta de ácido sulfúrico N°1
		Planta de ácido 1	I205	Planta de ácido 1 Gral.
			I208	Planta de ácido 1 Gral.
			I209	Planta de ácido 1 Gral.
3	Convertidores y Hornos de Limpieza	Sopladores de Convertidores	I093	BLOWER #6
			I094	BLOWER #5
			I092	BLOWER #7
			I042	BLOWER #1 Convertidor 4
			I043	BLOWER #2
			I229	Soplador de convertidor Gral.
		Operación Convertidores Gral.	I514	290-MCC-001
		I046	Operación de conver. Gral.	

			I235	Operación de conver. Gral.
			I098	Operación de conver. Gral.
			I056	Blower Room N°1
			I231	Oper. De Conver. Gral.
		Hornos de limpieza	I096	Barra LC-101 480V Converter Área
4	Manejo de Gases y Polvos	Precipitador de Convertidor 2	I233	Precipitador de conv. 2
			I231	Precip. Conv.2
			I235	Precipitador de conv. 2
		Precipitador del ISA	I559	310-PXF-001
			I558	310-ESP-001
			I535	310-FAN-001
		Precipitador Convertidores (CPS)	I517	321-MCC-001
			I516	320-ESP-002
			I515	320-ESP-001
			I514	290-MCC-001
		Manejo de Gases CPS	I561	320-MCS-002 - Transformer 320-VFD-002/ 320-FAN-002
			I560	320-MCS-001 - Transformer 320-VFD-001/ 320-FAN-001
			I514	290-MCC-001
			I517	321-MCC-001
		5	Toma de Agua de Mar	Toma de agua de mar
I528	620-PMP-003			
I522	620-PMP-001			
I530	620-MCC-002			
I534	620-MCC-001			
6	Horno ISASMELT y Hornos RHF	Horno de Fusión ISASMELT	I202	00931-US-A
			I550	Área 612
			I554	220-MCC-002
			I555	220-MCC-001
			I229	Horno de fusión isa gral.
			I212	00914 CM Metering 4.16 KV
			I203	00931-US-B
			I213	00914 CM Metering 4.16 KV
			I087	Iluminación - Preheater control RoomPreheater control Room
			I100	Iluminación - Preheater control Room
			I102	Iluminación - Preheater control Room
			I103	Iluminación - Preheater control Room
			I088	Iluminación - Preheater control RoomPreheater control Room

			I101	Iluminación - Preheater control Room
			I104	Iluminación - Preheater control Room
			I105	Iluminación - Preheater control Room
			I091	Blower 3
			I211	New CMT Blower
			I209	Horno de fusión isa gral.
		Soplador del ISA	I562	270-BLO-001
		Hornos RHF	I557	230-MCC-002
			I553	230-MCC-001
7	Distribución Aire Comprimido	Servicio de aire comprimido	I095	Centac (DCS KWH) 600HP
			I230	DCS-kWh Comp. EPE300#1
			I245	630-ACO-001
			I228	DCS-KWH Comp. EPE300 # 4
			I232	DCS-KWH Comp. EPE300 # 2
			I234	DCS-KWH Comp. EPE300#3
8	Planta Desalinizadora y Potabilización	Planta desalinizadora	I521	640- ACO-002
			I520	640- ACO-001
			I529	640-PDP-001
9	Planta de Ánodos	Planta de ánodos	I544	295-MCC-001
			I246	Pta. De ánodos y moldeo Gral.
			I548	294-MCC-001
			I549	295-MCC-002
		Moldeo	I233	Moldeo General
			I056	Blower Room N°1
			I231	Moldeo Gral.
			I046	Moldeo Gral.
10	Varios	Gerencia de Mantenimiento	I231	Ger. Mtto.
			I057	Gerencia de Mantenimiento
			I237	Transformer 4.16/0.48kV Slag Haulers//Maintenance Shop
		Ilum. Pública & Edif. Públicos	I040	Iluminación Pública & Edif. Públicos
11	Preparación de Minerales	Manejo de Concentrados	I039	130-MCC-002
			I040	Manejo de Concentrados Gral.
			I235	Manejo de Concentrados Gral.
			I545	130-MCC-001
12	Preparación de Fundentes	Chancadora de Fundentes	I542	140-CRU-001 400HP
			I546	140-MCC-002
			I040	Chancadora de fundentes
			I214	Chancadora secundaria cónica de

				fundentes
			I209	Chancadora de fundentes
13	Planta de Cal	Planta de cal	I238	MCC131
			I059	Cuarto eléctrico Planta de Cal
			I060	Cuarto eléctrico chancadora antigua
			I239	Variador de 350HP Horno de Cal
14	Planta de Efluentes	Tratamiento de Efluentes 2	I565	Transformer 460-XFR-001 4.16/0.48kV
		Tratamiento de Aguas Servidas	I533	690-MCC-001
			I221	E.R. Water Pumping Plant
	Varios	Ilum. Pública & Edif. Públicos	I216	Ilum. Pública & Edif. Públicos

Fuente: Área Mantenimiento Eléctrico (SCC)

Elaboración: Propia

ANEXO 2

Glosario

ANN (RNA)	:	Artificial Neural Network. Red Neuronal Artificial
IGV	:	Inlet Ga Valve. Válvula de regulación de álabes
MAC	:	Main Air Compresor
POX	:	Planta de Oxígeno
MCC	:	Motor Central Control
DCS	:	Distributed Control System
PMI	:	Project Management Institute
SCC	:	Southern Copper Corporation
PAS	:	Planta de Ácido Sulfúrico

BIBLIOGRAFÍA

- Aussem, A., Murtagh F. y Sarazin M. (1995) *Dynamical recurrent neural networks – towards environmental time series prediction*, International Journal Neural Systems, pp. 145–170.
- Carrasco, R., Forcada, C., Valdés-Muñoz M, y Neco, R. (2000) *Stable-encoding of finite-state machines in discrete-time recurrent neural nets with sigmoid units*, Neural Computation, pp. 2129–2174.
- Castaño, M., Vidal E. y Casacuberta , F. (1995) *Finite state automata and connectionist machines: a survey*, en New trends in neural computation, vol. 930 de Lecture Notes in Computer Science, pp. 433–440, Springer-Verlag.
- Elman, J. L. (1990) *Finding structure in time*, Cognitive Science, pp. 179–211.
- Elman, J. L. (1991) *Distributed representations, simple recurrent networks, and grammatical structure*, Machine Learning, pp. 195–225.
- Forcada, M. L. y Gori, M. (2001). *Neural nets, recurrent*, en J. G. Webster, coordinador, Wiley Encyclopedia of Electrical and Electronics Engineering, John Wiley & Sons.

- Gertler J. (1998). *Fault detection and diagnosis in engineering systems*. Marcel Dekker. Inc.
- Haykin, S. y Li, L. (1995) *Non-linear adaptive prediction of nonstationary signals*, IEEE Transactions on Signal Processing, pp. 526– 535.
- Hochreiter, S. y Schmidhuber, J. (1997). *Long short-term memory*, Neural Computation, pp. 1735–1780.
- Hopcroft, J. E. y Ullman, J. (1979) **Introduction to automata theory, languages and computation**, Addison-Wesley.
- Iserman, R. (1984) *Process fault detection based on modeling and estimation methods*. Automatica 20, pp. 387–404.
- Iserman R., (1980) *Practical aspects of process identification*, Automatica, 16, pp. 575-587.
- Kechriotis, G., Zervas, E. y Manolakos, E. (1994) *Using recurrent neural networks for adaptive communication channel equalization*, IEEE Trans. on Neural Networks, pp. 267–278.
- Kleene, S. C. (1956) *Representation of events in nerve nets and finite automata*, en C. E. Shannon y J. McCarthy, coordinadores, Automata studies, Princeton University Press.
- Ljung, L. y Glad, D. (1994) *Modeling of Dynamic Systems*. Prentice-Hall,
- Ljung, L. (1999) *System identification: theory for the user*. 2da ed. Prentice-Hall, Englewood Cliffs.

- McCulloch, W. S. y Pitts, H. (1943) *A logical calculus of the ideas immanent in nervous activity*, Bulletin of Mathematical Biophysics, pp. 115–133. Estados Unidos
- McCluskey, P. G. (1993). *Feedforward and recurrent neural Networks and genetic programs for stock market and time series forecasting*, informe técnico CS-93-36, Brown University.
- Minsky, M. L. y Papert, S. (1969) *Perceptrons*, MIT Press, Cambridge
- Mozer, M. C. (1994) *Neural network music composition by prediction: exploring the benefits of psychoacoustic constraints and multiscale processing*, Connection Science, pp. 247–280.
- Narendra, K. y Parthasarathy, K. (1990) *Identification and control of dynamical systems using neural networks*, IEEE Transactions on Neural Networks, pp. 4–27.
- Proakis, J y Manolakis, D. (1998). *Tratamiento digital de señales: principios, algoritmos y aplicaciones*, Prentice-Hall.
- Puskorius, G. y Feldkamp, L. (1994) *Neurocontrol of nonlinear dynamical systems with Kalman filter trained recurrent networks*, IEEE Transactions on Neural Networks, pp. 279–297.
- Robinson, J. y Fallside, F. (1991) *A recurrent error propagation speech recognition system*”, Computer Speech and Language, pp. 259–274.
- Siegelmann, H. T. y Sontag, E. (1991). *Turing computability with neural nets*, Applied Mathematics Letters, 4, pp. 77–80.

Sejnowski, T. y Rosenberg, C. (1987) *Parallel networks that learn to pronounce english text*, Complex Systems, pp. 145–168.

Seborg, D., Edgar, T. y Mellichamp, D. (1989) **Process Dynamics and Control** 1ra ed. Printence-Hall.

Werbos, P. J. (1974) *Beyond regression: new tools for prediction and analysis in the behavioral sciences*, tesis doctoral, Harvard University.

Williams, R. y Zipser, D. (1989) *A learning algorithm for continually training recurrent neural networks*, Neural Computation, pp. 270–280.