

a 307153



UNIVERSIDAD DE ALCALÁ REGISTRO GENERAL SECCIÓN II	
20 JUL. 2004	
ENTRADA Nº 3491	SALIDA Nº



UNIVERSIDAD DE ALCALÁ

DEPARTAMENTO DE CIENCIAS DE LA COMPUTACIÓN

Una nueva aplicación de las redes neuronales y la lógica difusa a la optimización del proceso de la fabricación del arrabio en un Horno Alto

Autor

Hussen Ghidan Hussen
Ingeniero en Informática

Directores

Javier Mochón Muñoz
Doctor en Ciencias Físicas

Tomasa Calvo Sánchez
Catedrática de Universidad

Alcalá de Henares Junio de 2004



T
62-05
UAH
GHI
Sala



Escuela Politécnica
Campus Universitario
28871 Alcalá de Henares (Madrid)
Telf.: (91) 885 66 45
Fax. : (91) 885 66 46

UNIVERSIDAD



DE ALCALÁ

DPTO. DE CIENCIAS DE LA COMPUTACIÓN

Dña Enriqueta Muel Muel, Profesora Titular de Universidad del Área de Ciencias de la Computación e Inteligencia Artificial, en calidad de Directora del Departamento de Ciencias de la Computación.

CERTIFICO: Que la Tesis Doctoral titulada: **“Una nueva aplicación de las redes neuronales y la lógica difusa a la optimización del proceso de fabricación de arrabio en un Horno Alto”**, realizado por D.Hussen Ghidan Hussen y dirigida por **Dr.D. Javier Mochón Muñoz y Dra.Dª. Tomasa Calvo Sánchez**, reúne los requisitos para su presentación y defensa pública.

Y para que así conste, firmo la presente en Alcalá de Henares, a 15 de Junio de 2004.



Fdo: Dña Enriqueta Muel Muel



Escuela Politécnica
Campus Universitario
28871 Alcalá de Henares (Madrid)
Telf.: (91) 885 66 45
Fax.: (91) 885 66 46

UNIVERSIDAD



DE ALCALÁ

DPTO. DE CIENCIAS DE LA COMPUTACIÓN

Dr. D. Javier Mochón Muñoz, Investigador Científico del Centro Nacional de Investigaciones Metalúrgicas del Consejo Superior de Investigaciones Científicas (Cenim del CSIC).

Dra. D^a. Tomasa Calvo Sánchez, Catedrático de Universidad en el área de Ciencias de la Computación e Inteligencia Artificial, del Departamento de Ciencias de la Computación de la Universidad de Alcalá.

HACEN CONSTAR

Que la memoria de tesis doctoral titulada " **Una nueva aplicación de las redes neuronales y lógica difusa a la optimización del proceso de fabricación de arrabio en un Horno Alto**", ha sido realizado por D. Hussien Ghidan Hussien bajo nuestra dirección en el departamento de Ciencias de la Computación. Este trabajo contiene aportaciones teóricas y prácticas, que se han contrastado adecuadamente mediante las validaciones oportunas. Por todo ello consideran que procede su defensa pública.

Y para que así conste, firman la presente en Alcalá de Henares, a nueve de junio de dos mil cuatro.

El Director de Tesis.

Dr. Javier Mochón Muñoz

La Codirectora de Tesis

Dra. Tomasa Calvo Sánchez.

ÍNDICE

RESUMEN	i
INTRODUCCIÓN	iii
ABSTRACT	vi
INDICE	a
INDICE DE FIGURAS	d
INDICE DE TABLAS	f
CAPÍTULO 1: ANTECEDENTES HISTÓRICOS	1
1. INTRODUCCIÓN	1
1.1 HISTORIA DE LA SIDERURGIA EN ESPAÑA	2
1.1.1 LA SIDERURGIA ESPAÑOLA EN LOS ÚLTIMOS AÑOS	5
1.2 MATERIAS PRIMAS	6
1.2.1 LOS MINERALES DE HIERRO	6
1.2.1.1 SINTERIZACION	7
1.2.1.2 PELETIZACION	8
1.2.2 CARBON	9
1.2.2.1 COQUE SIDERURGICO	9
1.3 EL HORNO ALTO	10
1.3.1 INSTALACIONES PRINCIPALES DEL HORNO ALTO	11
1.3.1.1 SISTEMA DE EVACUACIÓN DEL GAS	11
1.3.1.2 CUERPO DEL HORNO	11
1.3.1.3 EL SISTEMA DE REFRIGERACIÓN DEL HORNO	14
1.3.1.4 EL SISTEMA DE CONTROL	14
1.3.2 PROCESO GENERAL DEL HORNO ALTO	15
1.3.2.1 REACCIONES DE LOS GASES CON LOS SOLIDOS QUE DESCIENDEN AL CRISOL	17
1.3.3 CONTROL DEL PROCESO DEL HORNO ALTO	20
1.3.4 PRODUCCIÓN, PRODUCTIVIDAD Y CAMPAÑA DEL HORNO ALTO 21	
1.4 FUNCIONES DEL HORNO ALTO	22
1.5 EL ARRABIO, LA ESCORIA Y SUS FORMAS DE TRATARLOS	24
1.5.1 EL ARRABIO Y SU MANEJO	24
CAPÍTULO 2: REDES NEURONALES	25
2. INTRODUCCIÓN A LAS REDES NEURONALES	25
2.1 TIPOS DE REDES NEURONALES	25
2.1.1 PERCEPTRÓN MULTICAPA	26
2.1.2 REDES COMPETITIVAS	28
2.1.3 RED COMPETITIVA DE HAMMING	28
2.1.4 MAPAS AUTOORGANIZADOS	30

2.1.5 REDES L.V.Q ('LEARNING VECTOR QUANTIZATION') Y SUS MEJORAS	31
2.2 SISTEMAS BASADOS EN REGLAS BORROSAS.....	33
2.3 SISTEMAS DE INGENIERÍA COMO COMBINACIÓN DE LA INFORMACIÓN NUMÉRICA Y LINGÜÍSTICA.....	34
2.4 ANFIS: Sistema de Inferencia Borroso basado en redes adaptativas	35
2.5 REGLAS "SI-ENTONCES" BORROSAS.....	36
2.6 ARQUITECTURA DE SISTEMAS DE INFERENCIA BORROSOS.....	36
2.6.1 ARQUITECTURA DE SISTEMA DE INFERENCIA BORROSO BASADO EN UNA RED ADAPTATIVA. ARQUITECTURA DEL ANFIS	
2.11) 39	
2.7 ALGORITMO HÍBRIDO DE APRENDIZAJE.....	42
2.8 ALGORITMOS DE AGRUPACIÓN DE LA INFORMACIÓN ('CLUSTERING')	45
2.9 AGRUPACIÓN SUBTRACTIVA. ('SUBSTRUCTIVE CLUSTERING').....	46
CAPÍTULO 3: DATOS DE LOS SENSORES DEL HORNO ALTO SUS TRATAMIENTOS.....	49
3. INTRODUCCIÓN.....	49
3.1 LOS DATOS: Adquisición y Preparación.....	50
3.1.1 TEMPERATURA DEL ARRABIO: Preparación.....	57
3.2 REPROCESAMIENTO DE LOS DATOS.....	58
3.2.1 FILTRADO DE DATOS.....	59
3.3 ANÁLISIS DE LOS DATOS	62
3.3.1 HISTOGRAMAS DE LAS VARIABLES.....	62
3.3.2 ANÁLISIS DE LA CORRELACIÓN CRUZADA	67
3.3.2.1 CONCLUSIONES DEL ESTUDIO DE LAS CORRELACIONES.....	72
3.3.3 ANÁLISIS DE COMPONENTES PRINCIPALES.....	72
3.3.3.1 CONCLUSIONES DEL ESTUDIO DE LAS COMPONENTES PRINCIPALES.....	75
CAPÍTULO 4: APLICACIONES DESARROLLADAS USANDO "LOGICA BORROSA Y REDES NEURONALES"	77
4. MODELO PARA LA PREDICCIÓN DE LA TEMPERATURA DEL ARRABIO	77
4.1 APLICACIÓN DE LOS ALGORITMOS DE ENTRENAMIENTO.....	79
4.1.1 APLICACIÓN DEL ANFIS.....	80
4.1.2 APLICACIÓN DEL 'SUBSTRUCTIVE CLUSTERING'	80
4.2 RESULTADOS OBTENIDOS	81
4.3 MODELO DE SIMULACIÓN	84
4.3.1 EVALUACIÓN DE LAS ESTRATEGIAS DE AVISO AL OPERADOR.....	85
4.3.2 RESULTADOS OBTENIDOS	88
4.4 CONCLUSIONES SOBRE LA APLICACIÓN DEL ANFIS	88
4.5 APLICACIÓN REALIZADA USANDO REDES NEURONALES. ¿POR QUÉ EMPLEAR R.N.?	89
4.5.1 CRITERIO DE SELECCIÓN DE LA R.N. PARA ESTA APLICACIÓN	89
4.5.2 ESTRUCTURA DE LA RED NEURONAL PARA MLP	90

4.6	DIVERSAS PREDICCIONES USANDO R.N.S.	91
4.6.1	PREDICCIÓN DE LA COMPOSICIÓN DE LOS GASES DE DESCARGA.....	91
4.6.2	PREDICCIÓN DE LA TEMPERATURA DEL ARRABIO.....	94
4.7	LA SIMULACIÓN DEL PROCESO CON REDES NEURONALES.....	98
CAPÍTULO 5: CONCLUSIONES		101
FUTURO		102
PARTE ALTA DEL HORNO, POR ENCIMA DE LA CARGA		102
MEDICIONES EN LA PARED, CUBA Y ETALAJES.....		103
ZONA DE TOBERAS Y 'RACEWAY'		103
CRISOL DEL HORNO Y NAVE DE COLADA		104
MODELOS		105
BIBLIOGRAFIA		107

Índice de Figuras

1.1.- La forja de Mirandaola (ferrería vasca).....	3
1.2.- Esquema de una planta de sinterización.....	7
1.3.- Esquema de HA moderno.....	10
1.4.- Perfil de un horno alto.....	12
1.5.- Descenso de los materiales sólidos en el horno alto.....	16
1.6.- Relaciones entre temperatura, % monóxido de carbono y presión interior.....	17
1.7.- Reacciones fundamentales.....	17
1.8.- Curvas de equilibrio.....	18
1.9.- Reducción con mezcla de CO y H ₂	19
2.1.- Esquema de Perceptrón multicapa.....	26
2.2.- Red Hamming (Hamming Network).....	28
2.3.- Red competitiva ('Competitive Layer').....	29
2.4.- Mapa Autoorganizado.....	30
2.5.- Red L.V.Q.....	32
2.6.- Arquitectura de Sistema de Inferencia Borroso.....	37
2.7.- Reglas Si-Entonces borrosas y mecanismos de razonamiento borroso empleados normalmente.....	38
2.8.- (a) Modelo borroso de Sugeno de primer orden con dos entradas y dos reglas (tipo 3); (b) Arquitectura del ANFIS equivalente.....	39
2.9.- (a) Modelo borroso de Tsukamoto con dos entradas (tipo 1); (b) Arquitectura del ANFIS equivalente.....	41
2.10.- (a) Arquitectura del ANFIS para un modelo borroso de Sugeno con dos entradas y nueve reglas (tipo 3); (b) Espacio de entrada dividido en nueve regiones borrosas.....	42
2.11.- Aproximación lineal a trozos de las funciones de pertenencia de las consecuencias en las reglas borrosas del ANFIS de Tsukamoto (tipo 1).....	44
3.1.- Humedad de la soplante.....	52
3.2.- Inyección de carbón.....	53
3.3.- Caudal de la soplante.....	53
3.4.- Oxígeno de la soplante.....	54
3.5.- Temperatura de la soplante.....	54
3.6.- Relación mineral/coque.....	55
3.7.- Temperatura del arrabio.....	55
3.8.- Presión de la soplante.....	56
3.9.- Representación de unos 1.000 valores de la temperatura del arrabio reales (en azul) e interpolados (rojo).....	58
3.10.- Características de respuesta en frecuencia de los cuatro tipos básicos de filtros.....	59
3.11.- Representación de 100 datos del Caudal de la soplante.....	61
3.12.- Espectro de frecuencias para los 100 datos del Caudal.....	61
3.13.- Filtrado de la señal del caudal de la soplante donde la línea continua de color azul representa la señal antes del filtrado, y la línea roja después del filtrado.....	62

3.14.- Histograma de la humedad.....	63
3.15.- Histograma de la inyección de carbón	63
3.16.- Histograma del caudal.....	64
3.17.- Histograma del oxígeno	64
3.18.- Histograma de la temperatura de la soplante	65
3.20.- Histograma de la temperatura del arrabio	66
3.21.- Histograma de la presión	66
3.22.- Correlación cruzada entre la humedad y la temperatura del arrabio	68
3.23.- Correlación cruzada entre la inyección de carbón y la temperatura del arrabio	68
3.24.- Correlación cruzada entre el caudal y la temperatura del arrabio.....	69
3.25.- Correlación cruzada entre el oxígeno y la temperatura del arrabio	69
3.26.- Correlación cruzada entre la temperatura de la soplante y la temperatura del arrabio	70
3.27.- Correlación cruzada entre la relación mineral/coque y la temperatura del arrabio	70
3.28.- Autocorrelación de la temperatura del arrabio.....	71
3.29.- Correlación cruzada entre la presión y la temperatura del arrabio	71
4.1.- Esquema del sistema borroso.....	79
4.2.- Predicción de la temperatura del arrabio con el conjunto de entrenamiento que se han representado 1 000 datos	82
4.3.- Predicción de la temperatura del arrabio con el conjunto de entrenamiento que se han representado 300 datos	82
4.4.- Predicción de la temperatura del arrabio con el conjunto de validación que se han representado 1 800 datos.....	83
4.5.- Predicción de la temperatura del arrabio con el conjunto de validación que se han representado 400 datos.....	84
4.6.- Esquema del simulador borroso.....	85
4.7.- Respuesta de la temperatura del arrabio a los cambios en la humedad	86
4.8.- Respuesta de la temperatura del arrabio a los cambios en la inyección de carbón.....	87
4.9.- Respuesta de la temperatura del arrabio a los cambios en el caudal	87
4.10.- Perceptrón multicapa	90
4.11.- Predicción y error de %CO	92
4.12.- Predicción y error de %CO ₂	92
4.13.- Predicción y error de %H ₂	93
4.14.- Predicción de %CO con una aproximación autoregresiva.....	93
4.15.- Estructura de red neuronal	94
4.16.- Salidas Errores y predicciones de la red	95
4.17.- Estructura de la red neuronal para predecir la temperatura del arrabio	97
4.18.- Salida y diferentes predicciones de la red autopredictiva.....	97
4.19.- Salidas y diferentes predicciones de la red	97
4.20.- Esquema del simulador con R.N.....	98
4.21.- NN Simulator responses	99

Índice de Tablas

1.1- Control de materiales y fluidos de entrada y salida del horno alto.	21
2.2.- Los dos pasos del procedimiento híbrido de aprendizaje para el ANFIS.....	43
3.1.-Retrasos de las variables de entrada.	72
3.2.- Matriz de Covarianza.	74
3.3.- Matriz de valores y vectores propios.....	75
3.4.- Valores propios y % de la varianza acumulada de cada variable.....	75
4.1.- Entradas y Salidas del modelo de predicción temp. arrabio.....	95
4.2.- Variables de entrada a la Red Neuronal.	96

RESUMEN

Esta tesis se centrará en el estudio de la aplicación de sistemas, basados en redes neuronales y lógica difusa, para la fabricación de arrabio. En particular el control relativo a los parámetros del horno alto, tales como temperatura del metal líquido, nivel térmico del horno así como sistemas que ayuden al conocimiento de las relaciones entre los mapas de la temperatura, y otros factores como una ayuda a la optimización del uso de combustibles y coque en el proceso. La metodología propuesta para atacar estos problemas es evaluar y hacer predicciones con modelos basados en redes neuronales artificiales e inferencia difusa.

AGRADECIMIENTOS

Esta Memoria ha sido realizada bajo la dirección de los doctores: Javier Mochón - Investigador Científico del Dptº. de Metalurgia Primaria del Cenim/CSIC- y Tomasa Calvo Sánchez - Catedrática de Dptº. de Ciencias de la Computación (UAH), a quienes quiero mostrar mi más sincero agradecimiento. Su buena orientación, sus acertados consejos, su constante estímulo, su apoyo en la redacción definitiva del trabajo, y, en suma, su amplia dedicación, tanto científica como humana, han sido fundamentales para la consecución de los objetivos de esta Tesis.

En especial, agradezco profundamente a la Dra. Tomasa Calvo el haber sabido alimentar mi motivación para el estudio de este campo y al personal de los Departamentos de Ciencias de la Computación de la Universidad de Alcalá de Henares y de Metalurgia Primaria del Cenim/CSIC - Paquita Bueno- quienes se han portado conmigo como si fuesen mis padres y hermanos.

Asimismo, quiero expresar mi agradecimiento a la U.E que financió con una ayuda ECSC los trabajos en los que se ha basado esta Tesis, así como a la empresa Aceralía (Sr. Obeso, Sr. Sancho, de la División de I+D+i) por las facilidades de uso de las instalaciones de la factoría de Gijón.

Finalmente, y de manera muy especial, deseo dar las gracias a José Luis Calvo y a mi familia.

INTRODUCCIÓN

En el proceso de producción de arrabio, la evaluación de las condiciones del proceso está basada en diagnósticos aplicados a una variedad de condiciones operativas que a su vez sirven como base para que el operador tome decisiones y actúe. En particular, ha habido para el horno alto aplicaciones de las técnicas de control basadas en sistemas de conocimiento y supervisión de operación. Por ejemplo, el sistema GO-STOP desarrollado por Kawasaki Steel Corp., en 1977, fue un esfuerzo pionero. El sistema usó tres niveles de razonamiento: GO, que indica que se puede incrementar la relación de trabajo; STOP, indica que se deben mantener, sin cambios, las condiciones de trabajo; y BACK, que indica que es necesario un decrecimiento para controlar o evitar situaciones anormales. La esencia del método era simple y se correspondía bien con la toma de los operadores del proceso. Sin entrar en detalles las sentencias (juicios) GO, STOP, o BACK estaban hechas para cada parámetro operativo y éstos estaban clasificados en varios grupos característicos, que eran similares a los procesos de evaluación en tres niveles a los que se aplicaban. Además los juicios sobre las condiciones del horno alto se hacían sobre consideraciones del peso relativo de cada factor característico.

A pesar de que el sistema original se usó aproximadamente durante una década, no era capaz de trabajar con los cambios en niveles de producción o incorporar nuevos desarrollos de la tecnología. Por esta razón se adoptaron los sistemas en los que la base de conocimientos, o la nueva lógica añadida, se podía modificar de una manera relativamente fácil. Actualmente en la industria se usa el desarrollo de tales sistemas expertos de tipo diagnóstico junto con sofisticados modelos de simulación. Los sistemas supervisores del horno alto constan ahora de varios módulos que contienen simulaciones de la cuba, simulaciones del crisol, modelos termodinámicos, así como algún grado de optimización de procesos y diagnóstico asistido por ordenador tales como el GO-STOP.

El gran número de datos, de entrada- salida, del orden de 5.000, lleva aparejado un alto grado de procesamiento y automatización de los mismos. Dammert en 1991 presentó un sumario sobre las aplicaciones de tales tecnologías de control moderno de procesos a la producción de arrabio, mientras que Matsuda et al., en 1992, dio una visión sobre los trabajos de los japoneses en el área de los sistemas expertos para el control del horno alto, que recoge la experiencia de la compañía Kobe Steel. El modelado matemático de los hornos altos generalmente se ha realizado de una manera simplificada, tal como lo describe Bi et al (1992). Tales simulaciones, son relativamente simples y dividen el horno alto en varias regiones, siendo de uso práctico y han sido patrocinadas por organizaciones tales como la Asociación Sueca de fabricantes de Acero (Swedish Iron makers Association). La

mayor parte de los trabajos en esta área están basados en el trabajo original, en Japón, de Muchi (1967) y Muchi y Yagi (1970) y esencialmente son formulaciones unidimensionales que postulan un estado cuasi estable en el horno, despreciando las distribuciones radiales de las variables del proceso y la estructuración por capas de los materiales descendentes. No obstante las distribuciones longitudinales de la mayor parte de las variables del proceso, tales como la temperatura del gas y de la fase condensada, las relaciones de descomposición del carbonato cálcico, las pérdidas de la solución del coque y la reducción hierro mineral, así como la composición del gas, están bien predichas en un acuerdo razonable con las medidas realizadas con sensores de descenso hechas por Kobayashi et al. (1987) en la Kobe Steel. Naturalmente tales modelos contienen parámetros ajustables que deben sintonizarse con las condiciones de operación antes que pueda esperarse cualquier tipo de predicción.

En este estado de cosas, el interés ha ido derivando recientemente hacia el uso de redes neuronales artificiales al objeto de modelar los procesos debido a las grandes no linealidades y retardos del proceso de fabricación de arrabio. Trabajos recientes de Matsuda et al (1994) resumen el uso de las redes neuronales para reconocimiento de patrones a partir de los datos del horno alto. Se pueden encontrar anteriores intentos en Konishi et al (1990), Noel y Quemeneur (1990) Tamura et al (1991). El trabajo de Matsuda et al (1994) también discute el uso de inferencia difusa para predicción de los niveles de calor. Hay trabajos útiles porque exploran sistemáticamente parámetros tales como el tamaño de la base de datos para entrenamiento de la red así como varios factores internos tales como la selección del número de neuronas en las capas ocultas, factores de momento, factores de rapidez de aprendizaje, y hace comparaciones con datos testados. Tales aplicaciones son muy recientes y apenas se ha publicado más información sobre estrategias de control para la producción de arrabio, tanto basadas en redes neuronales como en lógica difusa.

Las innovaciones en esta Tesis provienen de varios factores: primero, las teorías difusas y de redes neuronales han empezado a ser aplicadas recientemente, a la fabricación de arrabio y principalmente como ayuda al reconocimiento, y el desarrollo de bases de conocimiento (véase Matsuda et al., 1994).

Con respecto a las redes neuronales la razón es clara. El problema principal está relacionado con el aprendizaje que es lento aun cuando se emplean grandes ordenadores. No obstante existe software disponible (Boger, 1995 y revisiones posteriores) en el que se usa principalmente análisis de componentes de las señales para asignar, a la red neuronal, pesos iniciales no aleatorios. Este permite conseguir tiempos de aprendizaje entre 20/100 veces más rápidos que con el empleo de pesos aleatorios, y hace que sea posible el usar PCs tipo Pentium aun cuando el número de

variables llegue a las 10.000. Estos desarrollos recientes, junto con los métodos para decidir sobre el número de neuronas en las capas ocultas, hacen que dichas tecnologías resulten mucho más atractivas.

En segundo lugar, el uso de controladores difusos y de control basado en redes y sistemas de asesoramiento para el operador no parece que hayan sido aún desarrollados para la fabricación de arrabio, aunque hay indicaciones de que pueden estar usándose, particularmente en Japón. Posteriormente se discutirán en detalles, ambos tipos de redes, las realimentadas y las recurrentes, que pueden entrenarse para aprender la dinámicas del sistema y luego son usadas como un modelo en estrategias variadas basadas en control modelado y sistema de asesoramiento al operador.

En tercer lugar, se propone aquí probar varias estrategias alternativas y evaluar su capacidad. Esto es deseable porque no está claro que grado de complejidad, se necesita en los sistemas de control y supervisión. Las medidas del funcionamiento tomarían por tanto la forma de un sistema de decisión que asigna una banda de crédito sobre las bases del error y de cambio en el error. Es posible realizar una modificación automática de los factores de escala, pero no está completamente claro hasta que punto constituye una forma de auto - organización necesaria para el funcionamiento de las plantas siderúrgicas y sólo puede dilucidarse contrastándolo con los resultados obtenidos del funcionamiento real de las mismas.

En suma, el área que se propone para investigar se ha considerado atractiva solo recientemente debido a que los avances en la tecnología de redes neuronales permiten operar con un gran número de variables de entrada.



ABSTRACT

This thesis is centered on the study regarding systems applications which are based on neural networks and fuzzy logic for the production of pig irons. In particular, the relative control of the blast furnaces, such as liquid metal temperature, blast furnace oven thermal level as well as systems that help us know the relationships between the temperature maps, as well as other factors as an aid in the optimization of the use of fuel and coke in said process. The methodology proposed to attack these problems is to evaluate and make predictions using models based on artificial neural networks and fuzzy inferences.



CAPÍTULO 1

ANTECEDENTES HISTÓRICOS

1. INTRODUCCIÓN

Como es sabido, el bronce y el cobre se utilizaron antes que el hierro. Este retraso puede explicarse por el elevado punto de fusión del hierro puro, que hacía prácticamente imposible que una vez tratados sus minerales se pudiese obtener en forma líquida separado de la escoria [58]. Se sabe que el pueblo hitita fue el primer siderúrgico, se tienen noticias documentadas de ello, y de que ya desde los años 4000 al 3000 antes de nuestra era, el hierro se empleaba en el antiguo Egipto, donde se sirvieron de herramientas de hierro para la construcción de las pirámides. Hacia el año 1000 antes de nuestra era, en los países que rodean el Mediterráneo, el hierro se abrió camino por todas partes. Los fenicios extendieron más tarde su comercio del hierro y de los metales por todo el mundo conocido.

El otro encuentro del hierro con el hombre sería casual. Seguramente preparó un hogar con ayuda de piedras de mineral y al cabo del tiempo, en ese hogar con combustibles carbonosos, se dio cuenta que había aparecido un material dúctil y maleable. Pero, seguramente también por casualidad, encontró que lo podía endurecer por cementación, es decir por la adición de carbono. Enseguida descubrió que llevándolo a una alta temperatura y enfriándolo en agua, podría aun mejorar este proceso de endurecimiento: así se descubrió el temple. Nuestros antepasados metalúrgicos se las ingenieron para, reproduciendo todo lo que la casualidad les había mostrado, poner a punto la reducción directa del mineral. Rodeaban a éste totalmente de carbón de leña y provocaban de esta forma el paso del óxido de hierro a hierro. Estos métodos rudimentarios de que disponía el hombre primitivo para activar la combustión en su pequeño horno, que construía en el suelo, no permitían lógicamente obtener una temperatura lo suficientemente elevada para fundir el metal. En su lugar obtenían una masa esponjosa, pastosa, mezcla de hierro y escoria que había que martillar repetidamente al rojo vivo, para eliminar la escoria e impurezas.

En todo caso, aunque al principio la obtención accidental del hierro colado pareció una desgracia, lentamente se fue reconociendo su verdadera importancia y seguramente que la palabra *afino* que utilizamos hoy en día para la obtención del acero a partir del hierro colado o *arrabio*, surgió entonces. En aquel momento los esfuerzos del hombre siderúrgico tuvieron varias opciones. Por una parte se desarrollaron los hornos hasta llegar a los hornos altos actuales, donde más adelante se sustituyó el carbón de leña por la hulla, y más concretamente por el coque. Esta sustitución fue una necesidad, porque en las comarcas donde estaban establecidas las empresas siderúrgicas se estaba produciendo un continuo agotamiento de sus bosques. Otro paso, más paulatino, consistió en ir aumentando las alturas de los hornos, con lo que, y precisamente aprovechando las características resistentes del coque, se podía aumentar las cargas de los mismos y en

consecuencia su producción. El tercer paso lo constituye el desarrollo para mejorar la marcha del horno mediante el aumento primero de la ventilación y el calentamiento del aire soplado después.

Pero el invento trascendental ocurrió en 1855, cuando Sir Henry Bessemer desarrolló el convertidor con soplado de aire (“oxígeno no puro”) por el fondo, que marca el paso revolucionario de la obtención del acero a partir del hierro colado o arrabio producido en el horno alto. Este importante desarrollo lo completa Thomas en 1873, al conseguir convertir el hierro colado de alto contenido en fósforo en acero de calidad, utilizando un convertidor similar pero con revestimiento básico. El siglo XIX fue igualmente fértil en el desarrollo de tecnologías de transformación del acero producido, tales como una amplia serie de técnicas de laminación para obtener productos planos y largos (chapas, vigas, carriles, tubos, etc.), así como en el desarrollo de máquinas y equipos de amplia aplicación en la siderurgia.

1.1 HISTORIA DE LA SIDERURGIA EN ESPAÑA

En España, los ligures primero y los celtas y romanos después, descubrieron enseguida nuestras riquezas en mineral de hierro e implantaron sus rudimentarias industrias siderúrgicas, poco después de que comenzase la gran difusión del hierro por el Mediterráneo [58].

El mineral de hierro máspreciado estaba en las minas celtibéricas del Moncayo, Inbilbilis (Calatayud) y Turiason (Tarazona) que adquirieron justa fama entre los romanos por la alta calidad y temple de las espadas allí fabricadas. También hay que destacar el desarrollo de la producción de acero que lograron los árabes que habían invadido la península ibérica. De todos es conocida la calidad de las armas que se fabricaron en Toledo. Se ha señalado que en Toledo conocieron las técnicas de producción que llegaron a dar gran prestigio a las espadas de Damasco. El proceso de Damasco, como se sabe, estaba basado en la producción de acero líquido de alto contenido en carbono, tal como se llegó a hacer en algunos lugares de la India, y en la forja perfecta del acero.

Posteriormente hay otro despegue espectacular de la siderurgia española que se produce en la Edad Media sobre todo en dos regiones, Cataluña y País Vasco, allí donde se encuentra el agua motriz, el mineral y el combustible, lo que hace posible la instalación de las “fargas” catalanas y las ferrerías vascas (Figura 1).




Figura 1.1.- La forja de Mirandaola (ferrería vasca).

No podemos olvidar otra región de gran tradición metalúrgica, Asturias, donde existían asimismo numerosas ferrerías ya en los albores del siglo XVIII. Algunos consideran como primer horno alto el que establecería el Marques de Sargadelos (Antonio Raimundo) en esa localidad gallega en 1797, mientras que otros consideran que fue el que funcionó a partir de 1832 en Heredia (Málaga), seguido del construido en Guriezo (Cantabria) por la sociedad bilbaína “Ybarra, Mier y Cia”.

Se sabe que en 1844 funcionaban los hornos altos Daoiz y Velarde de la Fábrica de Cañones de Trubia, dirigida por el general Elorza y el 14 de junio de 1848 arrancó el horno alto de la sociedad “Santa Ana” de Bolueta (Vizcaya), así como en 1858 el de la Fábrica de la Vega, en Langreo, que disponía ya de baterías de coque. La minería del carbón y del hierro favorecería la captación del capital extranjero y la generación de capitales propios para la creación de la siderurgia asturiana y vizcaína. Las hematites bajos en fósforo existentes en el anticlinal de Bilbao constituían las mejores minas europeas, y eran especialmente adecuados para el empleo del convertidor Bessemer, recién inventado en 1855, estando además excelentemente comunicados por ferrocarril y cable aéreo con los cargaderos de la ría y puerto de Bilbao. En el quinquenio 1866/70 se produjeron un promedio de 159.000 t de mineral/año, producción que llegó a la astronómica cifra, para la época, de 5.487.000 t mineral/año de promedio en el quinquenio 1896/1900.

Ya en 1875 existían tres importantes empresas asturianas. En ese año el francés Numa Guillhou funda la sociedad Fábrica de Mieres, contando con dos hornos altos y baterías de coque. También en 1875 la empresa Duro y Compañía, cuyo principal promotor fue el logroñés Pedro Duro (arrancó su primer horno el 5 de enero de 1860), producía ya un tercio del hierro español y pasaría a ser Duro Felguera a partir de 1904. La tercera gran empresa asturiana fue la Fábrica de Moreda y Gijón, constituida con capital francés y dirigida por los ingenieros franceses hermanos Claudel.

En 1880 arrancan en Sestao los dos hornos altos de la nueva compañía San Francisco de la Mudela, creada por el Marqués de la Mudela y su sobrino Martínez de las Rivas, importantes productores de mineral, fabricando en 1881 un tercio del hierro español y siendo hasta 1885 la mayor siderurgia española. En 1882 se constituye la empresa Sociedad Anónima de Metalurgia y Construcciones “Vizcaya” (La Vizcaya), con el 100 % de capital bilbaíno y con tecnología belga, impulsada por tres ingenieros: los hermanos Chávarri y J. A. de Olano. Víctor Chávarri sería un personaje decisivo, que logró el arranque de los hornos altos de Sestao el 17 de junio y el 8 de diciembre de 1885. Puso en marcha la batería de coque en 1889, trabajando hasta entonces con coque inglés y siendo la segunda empresa siderúrgica española, tras Altos Hornos de Bilbao (AHB).

También en 1882 se constituye Altos Hornos de Bilbao, en Baracaldo, sobre los terrenos de la fábrica de El Carmen. El capital procedía de Madrid (Urquijo, etc.), Cataluña (Girona, etc.), Francia (Angoloti, etc.) y del grupo vasco, principalmente Ybarra, Zubiría y Vilallonga. El ingeniero catalán Vilallonga, de familia siderúrgica y yerno de Ybarra, fue su primer presidente. La tecnología fue inglesa y los nuevos hornos entraron en servicio en 1887 y 1888, arrancando los convertidores Bessemer el 4 de febrero de 1886. En 1885 AHB era la segunda compañía en España, entre todas las existentes dedicadas a cualquier actividad tras la empresa de capital inglés Compañía Río Tinto. El desarrollo tecnológico de las tres empresas vizcaínas fue espectacular, con aumentos paulatinos e importantes de la productividad, de tal forma que en 1890 producían ya el 67 % del lingote de hierro español, la práctica totalidad del acero Bessemer, el 64 % del acero Martin-Siemens y el 67 % de los productos laminados y martillados.

Tras un breve antecedente de una planta en Ronda (Málaga), la hojalata empezó a producirse por inmersión en la fábrica de La Iberia (1887) y en La Basconia (1894), ambas cerca de Bilbao, compañías estas que se integraron luego en AHV. El 26 de junio de 1901 las sociedades La Vizcaya, AHB y la dedicada a la producción de hojalata La Iberia, acuerdan integrarse en una nueva compañía denominada Altos Hornos de Vizcaya (AHV). En 1919, absorbió a la siderurgia integral de San Francisco de la Mudela de Sestao y en 1940 a la Compañía Siderúrgica del Mediterráneo de Sagunto (fundada en 1914). AHV lideró el sector siderúrgico español hasta bien entrada la segunda mitad del siglo XX.

El 15 de junio de 1950 el Gobierno dictó un decreto encargando al INI la construcción de ENSIDESA, en Avilés, que arrancó sus hornos altos en 1957, 1958, 1966 y 1969, pasando a ser la primera siderurgia del país. Las tres primeras siderurgias asturianas antes aludidas arrancaron nuevos hornos altos entre 1955 y 1959, para fusionarse al comienzo de los años 60. Posteriormente, y acogándose a la acción concertada del Gobierno, crearon la nueva siderurgia integral UNINSA en 1966, que reforzaría la posición de ENSIDESA al ser absorbida por ésta a finales de 1973. Por otra parte en 1904 se instaló en España el primer horno eléctrico para producción de acero en Araya (Álava). Y en 1960 arrancó la primera instalación española de colada continua en San Adrián de Besos (Barcelona). Con el horno eléctrico y la colada continua se originó el concepto de miniplanta, principalmente para la producción de redondos para hormigón. La presencia de las miniplantas en España ha significado una importante contribución a la producción global de la siderurgia española.

1.1.1 LA SIDERURGIA ESPAÑOLA EN LOS ÚLTIMOS AÑOS

La siderurgia española, con una producción – en la década de los noventa- expresada en producto acabado entre 12,5 millones t/año y 13,5 millones t/año, supone del orden del 10 % de la producción de la Unión Europea. Esos 13 millones se subdividen en 11,5 millones t/año de acero común (5,5 millones de productos planos y 6 millones de productos largos) y 1,5 millones t/año de productos de acero especial, de los que 0,8 millones t/año son productos de acero inoxidable. Se han efectuado varias reestructuraciones desde la crisis de los años 70, obteniéndose importantes aumentos de productividad, reducciones de capacidades de producción excedentarias, así como la modernización de las instalaciones y de los productos, pasando por un proceso de concentración y privatización de empresas. Según datos de UNESID, desde 1986 a 1996 la productividad ha pasado de 242 t/hombre y año a 529 t/hombre y año, la plantilla se ha reducido en un 53,3 % y la capacidad máxima de producción de laminados en caliente ha pasado de 21 millones de t/año a 16,8 millones de t/año, reduciéndose un 20 %. En la siderurgia integral se ha pasado de dos a una única empresa; en la fabricación de acero común vía horno eléctrico de 22 grupos a 5 grupos de empresas y en la producción de aceros especiales de 15 empresas a 3 grupos empresariales. No se ha incluido en las compañías anteriormente aludidas, las 3 empresas que fabrican tubos sin soldadura y disponen de producción propia de acero.

La siderurgia española ha reducido sus costes, ganando en competitividad y mejorando su gestión, llegando de manera eficiente a un mercado globalizado y entrando en el próximo milenio en condiciones favorables para su éxito técnico y económico.

1.2 MATERIAS PRIMAS

Las materias primas requeridas en los procesos de producción de arrabio y acero, son fundamentalmente [58]:

- Las materias primas férricas (minerales de hierro y aglomerados como el sinter y el pellet).
- Las materias primas combustibles y agentes reductores (carbón, coque siderúrgico, gases y otros combustibles).
- Las materias primas fundentes (caliza, dolomía, cal, elementos para aleación, etc.).

1.2.1 LOS MINERALES DE HIERRO

El hierro, elemento básico constitutivo del acero, se encuentra en abundancia en la naturaleza bajo la forma de minerales de hierro, que son compuestos de hierro y oxígeno (óxidos diversos o carbonatos de hierro) junto con otros elementos o compuestos que se consideran impurezas (la ganga). El mineral de hierro es una materia prima fundamental para la siderurgia integral, basada en el proceso del horno alto. Será preciso proceder a una eliminación del oxígeno o reducción de los minerales, con descenso de las impurezas hasta los niveles requeridos. Existen diversos tipos de minerales de hierro, según varíen fundamentalmente los compuestos de hierro y oxígeno: magnetita, basada en el compuesto óxido ferroso-férrico Fe_3O_4 ; hematites, basada en el compuesto Fe_2O_3 ; limonita, basada en un óxido ferroso-férrico hidratado $\text{Fe}_2\text{O}_3\text{-H}_2\text{O}$; siderita, constituida por carbonato de hierro. Las riquezas en hierro (ley de hierro) de estos minerales varían según su composición, así como su aspecto físico, características, impurezas más habituales, etc. La extracción, enriquecimiento y preparación de los minerales son actividades propias de la minería. Se enriquece el mineral reduciendo su contenido en ganga (lavado, separación por flotación, magnética, etc.) y se prepara mediante operaciones de trituración y cribado, obteniéndose:

- Minerales gruesos, que podrían ser usados, en las proporciones y calidades precisas, como materia prima del horno alto. Se exigiría, además de una granulometría y una composición química determinadas.
- Minerales finos y concentrados (ultrafinos) destinados a los procesos de aglomeración que a continuación figuran (no pueden usarse directamente en el horno alto).

Habitualmente se utilizan minerales diversos, y se procede a su mezcla u homogeneización en grandes pilas o parvas de homogeneización, que además cumplen misiones de parques de almacenamiento controlado. Dentro de los procedimientos de aglomeración, distinguimos la sinterización y la pelletización.

1.2.1.1 SINTERIZACION

Es el proceso de aglomeración de los minerales finos para la obtención del sinterizado (o sinter), cuyo empleo en el horno alto favorece su marcha correcta (calidad, productividad y consumos específicos optimizados). A la mezcla de minerales finos, procedente de la parva de finos homogeneizada, se le adiciona agua y se noduliza en el tambor mezclador con vistas a optimizar su permeabilidad. Tras aportar la cantidad de combustible y de aditivos preestablecida, es cargada con un tambor alimentador cuidadosamente controlado, sobre la cinta o banda de la máquina de sinterizar, constituida por una serie de carros o “pailas” dotados de parrillas protegidas por una capa de “cama” de sinterizado de granulometría precisa (Figura 1.2).

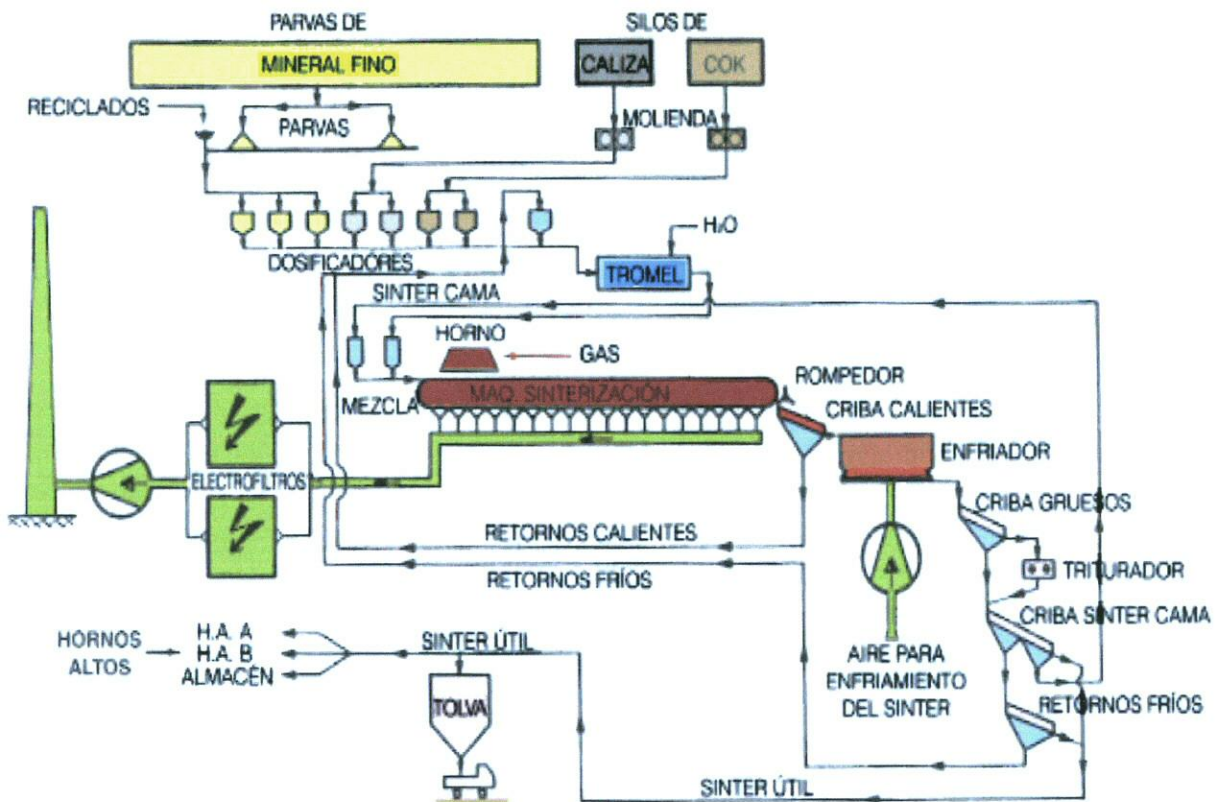


Figura 1.2.- Esquema de una planta de sinterización.

Todo ello constituye la carga que la máquina arrastra. Pasa por el horno de ignición, donde el frente de llama avanza de arriba abajo. Una soplante extractora de gran capacidad hace pasar el aire a lo largo de toda la superficie de la banda, produciendo una depresión a través de las cajas de aspiración en que está dividida la superficie total. El accionamiento de la soplante está constituido por un motor de gran potencia: del orden de 10 MW (uno de los mayores motores del conjunto de las instalaciones de toda la siderurgia integral) y cuyo dimensionamiento es función fundamentalmente de la superficie de la máquina y de la depresión utilizada (factores de diseño que afectan a la capacidad productiva, medida habitualmente por la relación de toneladas de sinter útil producidas por metro cuadrado de superficie de máquina y por día). El combustible más utilizado es el polvo de coque (granulometría, cenizas, humedad, etc. controladas). Los aditivos, normalmente caliza preparada, garantizan un contenido en escorificable y basicidad del sinter previsto para el proceso del horno alto.

Se obtiene una torta de aglomerado sinterizado, que después de troceada en el rompedor, es cribada en caliente, posteriormente enfriada por paso de aire en el enfriador y estabilizada (triturada y cribada en frío) para obtener un sinter de la mejor calidad: composición química (ley en hierro, escorificable, basicidad, contenido en álcalis, fósforo, etc.), características físico-químicas (dureza, reductibilidad, degradación en caliente, contenido en ferroso, etc.) y granulometría adecuadas, para optimizar el proceso de fabricación del arrabio en el horno alto.

1.2.1.2 PELETIZACION

La pelletización (o peletización) es el procedimiento de aglomeración de los minerales ultrafinos y concentrados para la obtención de pequeños nódulos o pellets, de dimensiones del orden de 10 mm a 15 mm, y con moderado grado de metalización. El proceso consiste en la obtención previa de los pellets verdes, formados en el tambor pelletizador con mineral fino de humedad controlada, al que se ha añadido un elemento o agente aglomerante. Posteriormente los pellets son secados y cocidos a alta temperatura para obtener el pellet de la calidad requerida: composición química (ley de hierro, cantidad, tipo y basicidad del escorificable, elementos residuales como álcalis, fósforo, etc.), características físico-químicas, etc.

Los factores determinantes del coste variable de los pellets están en línea con los apuntados para el caso del coste del sinterizado, teniendo en cuenta su proceso de fabricación específico. Los pellets son fácilmente transportables, por lo que (al revés que en el caso del sinterizado) las plantas de pelletización se encuentran normalmente en las proximidades de las minas.

1.2.2 CARBON

El carbón es una roca sedimentaria de estructura heterogénea que proviene de la fosilización de las plantas. Desde el punto de vista de combustible sólido, el carbón se caracteriza por su potencia calorífica, cuyo contenido es el siguiente: elementos propiamente combustibles (el carbono, el hidrógeno, etc.) y no combustibles (el agua, el nitrógeno, el oxígeno), y un resto de materias denominadas cenizas. La aplicación actual del carbón en la siderurgia se basa en su empleo como materia prima para la producción del coque siderúrgico y en la inyección de éste por las toberas del horno alto.

1.2.2.1 COQUE SIDERURGICO

El coque (también denominado cok) es el producto de la destilación del carbón en cámara cerrada y a alta temperatura. Se hablará de coque siderúrgico especialmente producido para su empleo en el horno alto, dadas sus características de:

- Agente reductor, sobre la base de su alto contenido en carbono.
- Agente térmico, sobre la base de su alto poder calorífico.
- Agente mecánico, sobre la base de su resistencia para soportar la carga del horno alto dotándole de la permeabilidad necesaria.

Se precisan unas determinadas características de los carbones para producir un buen coque siderúrgico, para lo que se emplean mezclas de hullas coquizables. Es importante la composición de los carbones, en especial su humedad, su contenido en azufre y su cantidad y tipo de cenizas, además de sus impurezas (fósforo, álcalis, etc.) y su contenido en materias volátiles. Las baterías de coque están constituidas por una serie de cámaras u hornos de coquizar de dimensiones variables, por ejemplo, en un entorno de 7 m de altura, 450 mm de anchura media y 16 m de longitud (volúmenes útiles de hasta 50 m³ y más).

Los hornos están contruidos en refractario de sílice y entre cada dos hornos existe una cámara de combustión donde se sitúan quemadores a lo largo de toda su longitud y a diferentes alturas, que mediante la combustión de gas aseguran el calentamiento de las paredes de sílice adyacentes y la obtención de las temperaturas adecuadas para la correcta coquización del carbón.

El empleo de la inyección de carbón en los hornos altos ha reducido las necesidades de coque siderúrgico, permitiendo bajar las marchas en la batería de coque aumentando su duración de vida, evitando a veces la reconstrucción de baterías y/o montaje de otras nuevas, etc. con los consiguientes beneficios en esta área. Se han desarrollado nuevas técnicas de coquización. La más interesante es el reactor de coquización Jumbo, que

supone una mejora de las condiciones de operación, un aumento de la productividad, un mejor control, un menor consumo energético, una menor contaminación, etc.

1.3 EL HORNO ALTO

La siderurgia integral utiliza la ruta del *horno alto* para la reducción de los minerales de hierro, eliminando el oxígeno y alcanzando un enriquecimiento en hierro metálico que se traduce en un alto grado de metalización, es decir, contenidos totales de hierro superiores al 95-96 %, con lo que se obtiene el *arrabio* [73]. El horno alto es un reactor vertical, de cuba, en el que se efectúa el proceso de reducción en contracorriente entre una carga descendente de sólidos y una ascendente de gas reductor, obteniéndose un producto intermedio: el arrabio. Este arrabio será tratado fuera del horno, normalmente en una planta de desulfuración y será posteriormente afinado en la acería LD para obtener el acero [58].

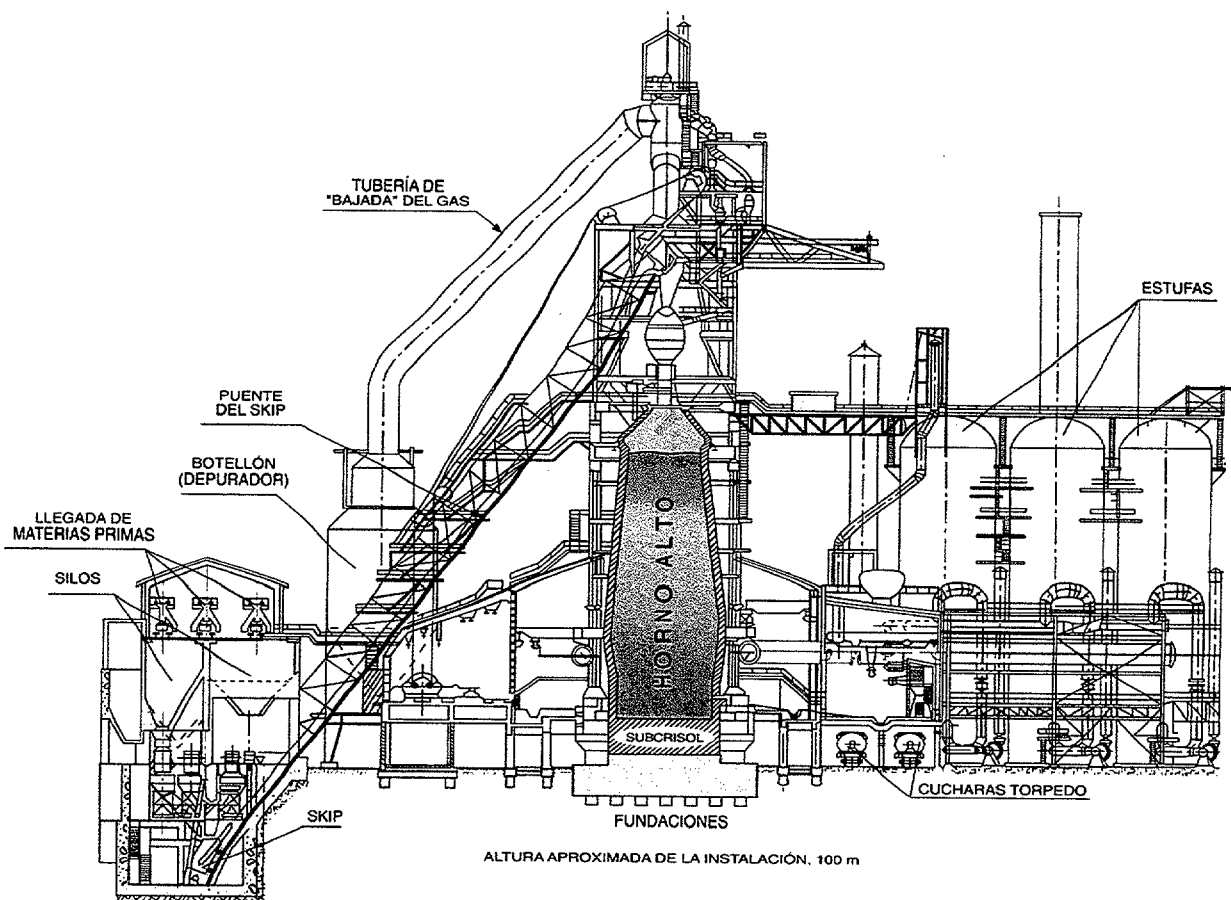


Figura 1.3.- Esquema de HA moderno

El horno alto ha demostrado alta eficiencia, adaptabilidad y capacidad productiva, a la vez que efectúa un cierto pretratamiento del producto obtenido, reduciendo los niveles de elementos no deseables en el arrabio producido (azufre, silicio, etc.) previo a su afino en la acería LD. Aunque el horno alto constituye probablemente el proceso siderúrgico más completo, se ha llegado a un elevado nivel tecnológico en su diseño y control, lo que junto con el proceso de acería LD, convierte a estas tecnologías en las más adecuadas para la obtención de elevadas cantidades de aceros de alta pureza y calidad, no alcanzable normalmente por otros métodos productivos.

1.3.1 INSTALACIONES PRINCIPALES DEL HORNO ALTO

El horno alto propiamente dicho está formado por una coraza construida en acero soldado y revestida interiormente de refractario con calidades en cada zona de acuerdo a las solicitaciones requeridas, y cuyo volumen interno está constituido por diferentes zonas cilíndricas y troncocónicas, en función de los materiales que en cada zona coexistan y de su estado (estado físico de los materiales y gases, así como volúmenes que ocupan en cada zona). En el horno alto se distinguen los siguientes sistemas principales:

1.3.1.1 SISTEMA DE EVACUACIÓN DEL GAS

Está constituido por las tuberías de evacuación del gas bruto pobre producido, denominadas *pantalones*. También está dotado de válvulas de descarga denominadas *cascabeles* o *chapines*, y controles de presión, temperatura, composición del gas, etc.

1.3.1.2 CUERPO DEL HORNO

El horno propiamente dicho, está construido a partir de material refractario de diferentes características, en función de las solicitaciones requeridas en cada zona y del diseño del horno, sostenido por un sistema de chapas y cajas de agua denominadas *staves*, constituyendo una coraza más o menos continua. Tiene un perfil que favorece su funcionamiento y el intercambio entre sólidos y gases, que en diferente estado coexisten en cada zona. El perfil del horno es variable a lo largo de su altura, distinguiéndose varias zonas (4).

En la figura 1.4, se representa esquemáticamente el perfil de un horno alto moderno. Como se aprecia, las partes más importantes del horno son:

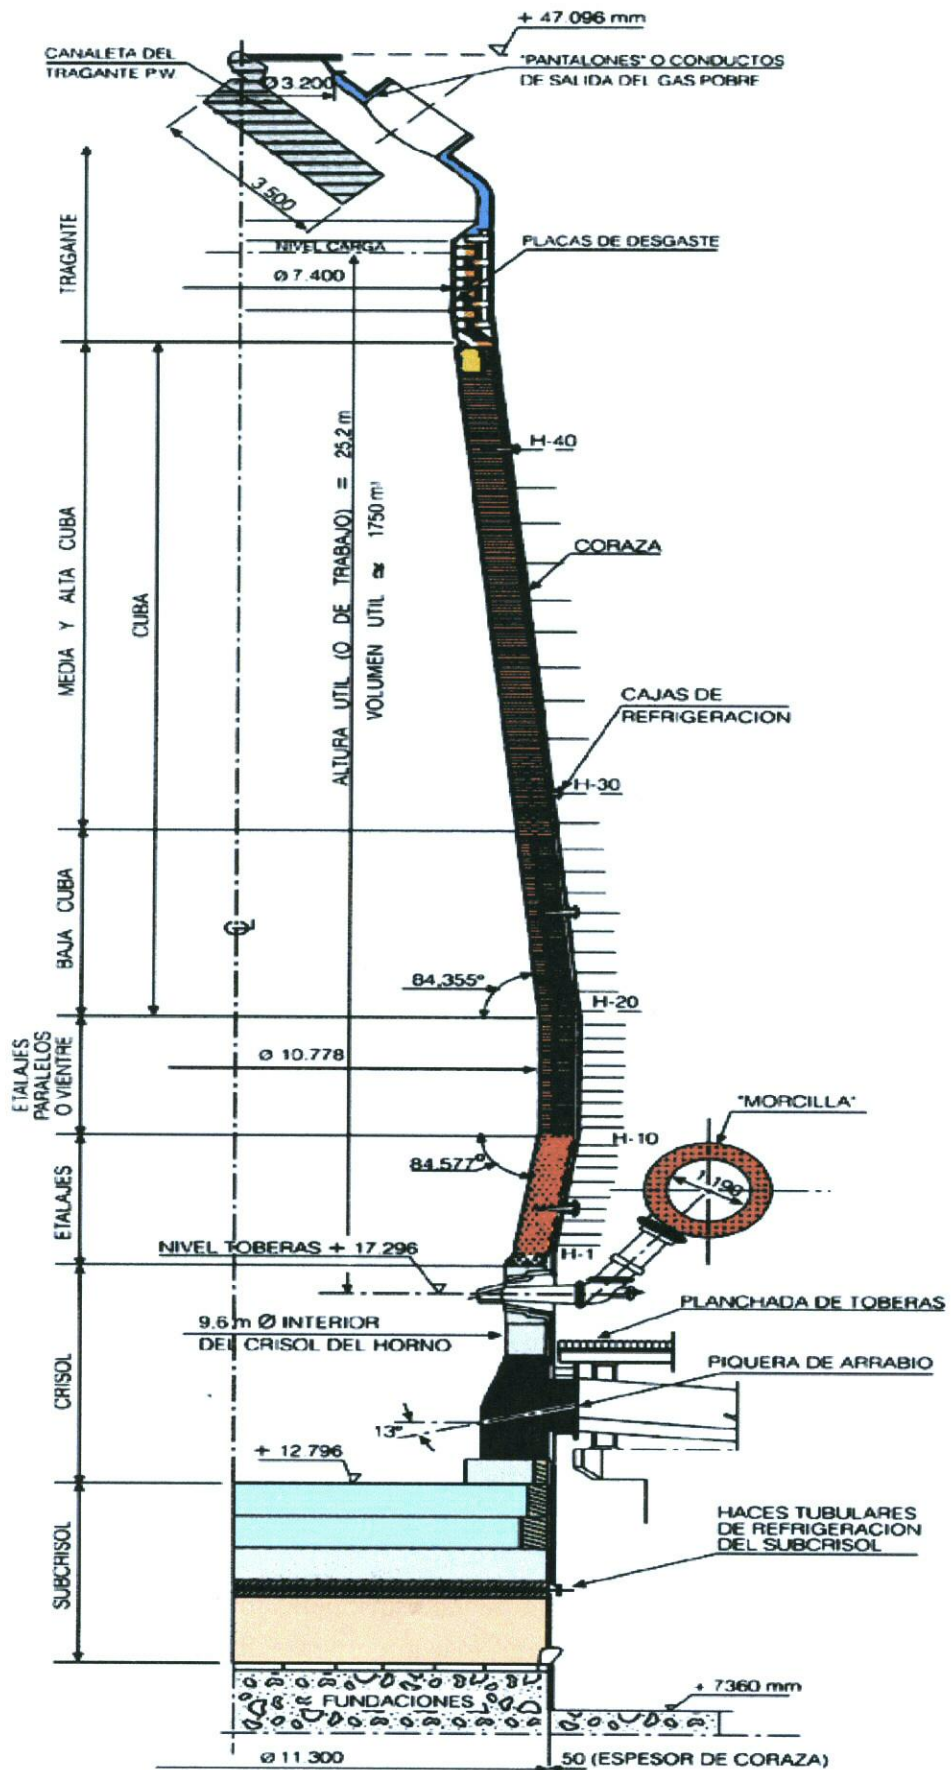


Figura 1.4.- Perfil de un horno alto.

Sistema de evacuación del gas. Situado por encima del horno, está constituido por las tuberías de evacuación del gas bruto pobre producido y dotado de válvulas de descarga denominadas “chapines” y controles de presión, temperatura, composición del gas, etc.

Tragante. Es la parte superior del horno por donde se cargan las materias primas constituidas por mineral de hierro, coque y fundentes. Formado de paredes rectas, la carga debe garantizar una distribución controlada de cada material en el interior del horno. Actualmente el sistema más extendido para controlar la distribución de carga es el diseñado por Paul Wurth frente al sistema de campanas. El tragante PW consiste en unas tolvas provistas de válvulas que alimentan una canaleta rotatoria cuyo ángulo de inclinación respecto a la vertical es posible regular mientras se realiza la carga de material al horno. De esta forma se puede distribuir la carga en una zona bastante amplia del tragante [13]. Este sistema, además mejora la estanqueidad y evita la emisión de gases y polvo, haciendo posible trabajar a mayor presión en el horno. Así pues, el sistema Paul Wurth es más económico, más fácil de instalar y mejora el funcionamiento respecto al sistema basado en campanas. [14].

Cuba. Situada entre el final del tragante y el vientre del horno. Contiene la mayor parte de la carga y tiene forma troncocónica coincidiendo su diámetro menor con el del tragante y el mayor con el del vientre. El perfil de la cuba ha de favorecer el intercambio de calor entre sólidos y gases que coexisten en diferentes estados.

Vientre. A continuación de la cuba, es de paredes rectas con lo que el horno vuelve a tomar una forma cilíndrica. Esta zona sirve de enlace entre la cuba y la zona de etalajes.

Etalajes. Es la zona del horno donde se inyecta el aire o viento caliente procedente de las estufas. El viento llega a una tubería circular o *morcilla* de la cual, a través de las tuberías de bajada, es introducido en el horno por los orificios de toberas. Su misión es hacer posible la combustión del carbón. El número de toberas varía de un horno a otro y es función del tamaño del mismo, pero siempre están equiespaciadas alrededor del horno. También en las toberas, se realiza la inyección de combustibles auxiliares.

Crisol. De forma cilíndrica, es la parte inferior del horno donde se recogen el arrabio y la escoria que serán periódicamente colados del horno a través de las piqueras o agujeros de colada.

1.3.1.3 EL SISTEMA DE REFRIGERACIÓN DEL HORNO

Es variable en función de cada zona del mismo, pero en cualquier caso es el más eficiente e intenso posible para mejorar la fiabilidad de marcha, la duración del revestimiento refractario y en última instancia optimizar la duración de la campaña del horno. En el horno coexisten varias tecnologías de refrigeración: la refrigeración por agua a alta presión de las toberas de doble cámara, la refrigeración por haces tubulares del subcrisol o la refrigeración intensa por cajas de cobre de doble cámara o por cajas verticales especiales o 'staves' de los etalajes y la cuba. Se precisan normalmente varios circuitos cerrados de refrigeración, empleando agua de calidad, con sus sistemas de bombas, torres de refrigeración, tratamiento del agua, etc., además de sistemas de control de temperaturas, presiones, caudales, cálculos de pérdidas térmicas, detección de fugas o fallos de elementos refrigerados, etc.

1.3.1.4 EL SISTEMA DE CONTROL

Tiene por objeto gestionar el funcionamiento de los equipos del horno y de su proceso. Multitud de sensores, tales como controles de temperatura, presión, sondas de nivel, sondas de análisis de gas, etc., están instalados en el propio horno junto con otros múltiples sensores de sus instalaciones auxiliares constituyendo un sistema global de control. El diseño del horno define su perfil, y existen varios parámetros característicos de la capacidad productiva: el diámetro interno del crisol (o bien su superficie), el volumen total del horno o capacidad interior entre las cotas de piqueta y del nivel teórico de llenado, el volumen útil o capacidad interior entre la cota de toberas y la del nivel teórico de llenado. Esos parámetros definen la dimensión del horno y ha podido constatarse una tendencia a un aumento de sus dimensiones, siendo habituales hornos altos con diámetros de crisol entre 10 m y 15 m con producciones diarias que pueden superar ampliamente las 10 000 t de arrabio. El coque actúa como combustible, agente reductor y aportador de carbono, además de como soporte de la carga. Por las toberas se inyecta el aire o viento caliente (controlando la humedad del viento y su inyección de oxígeno adicional), además de combustibles auxiliares como el carbón de inyección. Por el tragante o parte superior del horno se cargan materiales como los minerales, sinterizado, pellets y coque, fundamentalmente. Como salidas del horno, por las piqueras del crisol se cuela periódicamente el arrabio producido, que se separa de la escoria por densidad en las regueras de la planchada de colada. Las características térmicas del arrabio y de la escoria están determinadas por el proceso, además de por otros factores de menor incidencia (incluso por el tamaño del horno), y deben controlarse. Por el tragante se extrae también el gas pobre bruto (con cantidades altas de polvo que tras su depuración será utilizado como combustible). El horno alto es un eficiente reactor que funciona a contracorriente: los materiales sólidos cargados por el tragante descienden (con las transformaciones que el

proceso conlleva) hasta el crisol, mientras que los materiales introducidos por toberas ascienden como gases hasta el tragante sufriendo también diversas transformaciones.

El conjunto de reacciones a contracorriente que ocurren pueden analizarse desde el punto de vista de cada elemento químico (por ejemplo: reacciones de desulfuración o balance del azufre, etc.) o bien considerando aquí únicamente de forma simplificada las que más afectan al primordial objetivo del proceso: la reducción de los minerales de hierro. Las reacciones se favorecen con una adecuada permeabilidad en el horno y trabajando con alta presión en el tragante (trabajo a contrapresión).

Una alteración del proceso del horno puede derivar en un enfriamiento o “emborricamiento”, con muy graves repercusiones sobre la marcha, que puede tardar en normalizarse incluso varios días, exigiendo de los operadores de planta una pericia y esfuerzo adicionales.

1.3.2 PROCESO GENERAL DEL HORNO ALTO

Aunque la permanencia de la carga sólida en el horno alto es de bastantes horas (de doce a dieciocho horas), la permanencia de los gases es de muy pocos segundos (de tres a cuatro), y en este escaso plazo de tiempo los gases pasan de 1500 °C o 1600 °C hasta alrededor de 200 °C, que es la temperatura de los gases al salir por el tragante del horno. Debido al contacto íntimo de los gases con los materiales sólidos, el horno alto es un intercambiador de calor de un gran rendimiento, que pasa, en general, del 85 %. La carga sólida que entra húmeda y a la temperatura ambiente, va sufriendo una serie de transformaciones físicas y químicas como consecuencia de ir progresivamente alcanzando zonas de mayor temperatura y de mayor proporción de óxido de carbono en su composición, es decir, el horno alto es un aparato en el que se realizan las *reacciones fisico-químicas del proceso de reducción*. Esta reducción se realiza no solamente sobre los óxidos de hierro, cuya reducción puede realizarse a temperaturas relativamente bajas, entre 600 °C y 700 °C, sino que se extiende a la reducción de otros óxidos que acompañan al mineral o al combustible que se carga en el horno alto y cuya reducción se realiza, en general, a temperaturas más altas y con mayor proporción de CO. Por tanto, en zonas del horno más bajas y próximas a los etalajes y al crisol del horno alto, siendo reacciones fuertemente endotérmicas que absorben fuertes cantidades de calorías de nivel térmico alto. En este descenso de los materiales sólidos en el horno alto se producen, además, otras reacciones, como son: la descomposición de los carbonatos que se introducen en la carga, la formación de escoria y la eliminación parcial del azufre de la carga con la escoria. Para comprender bien el papel del horno alto como aparato en el que se van produciendo las reacciones químicas del proceso, se analiza a continuación lo que va ocurriendo en cada zona del horno alto a medida que descienden los materiales sólidos cargados en la zona alta (5).

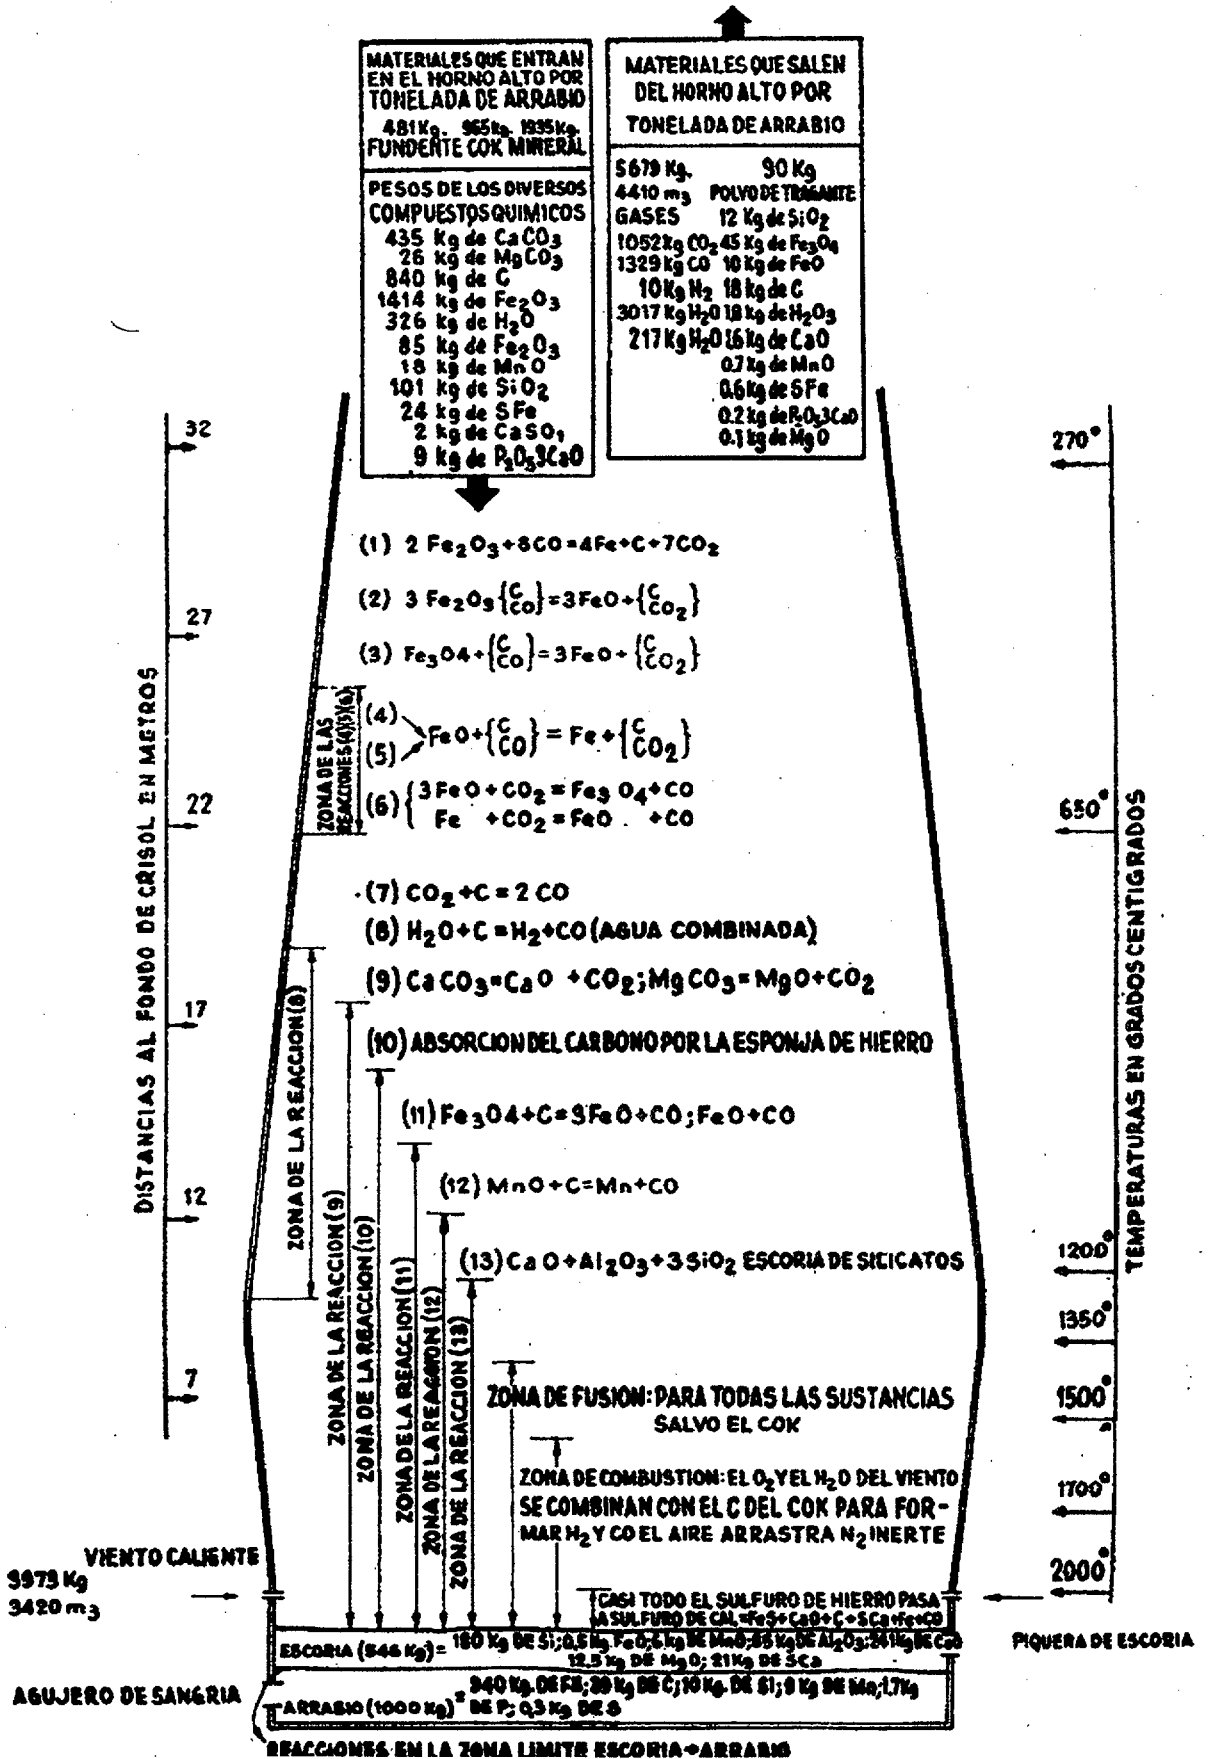


Figura 1.5.- Descenso de los materiales sólidos en el horno alto

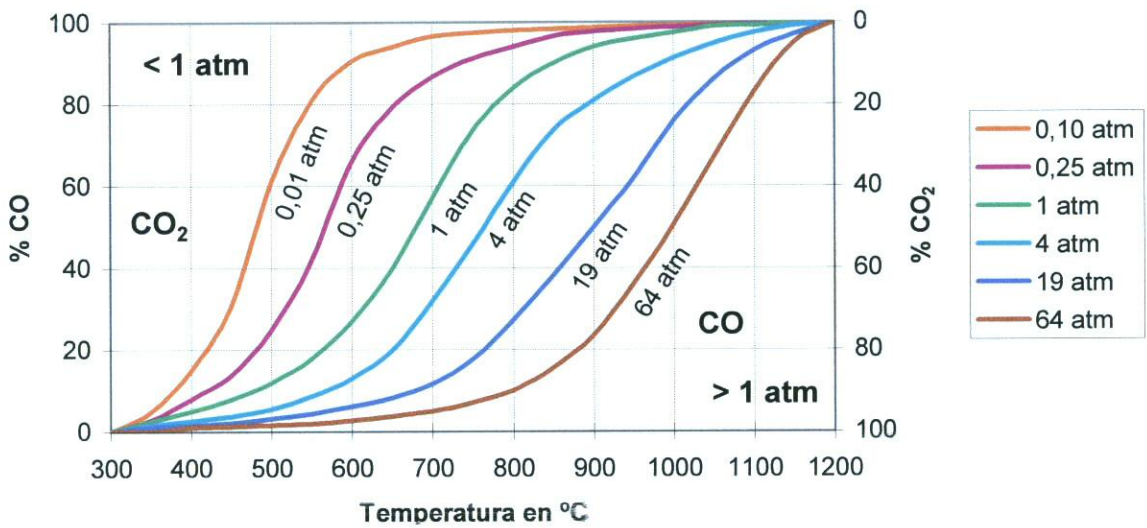


Figura 1.6.- Relaciones entre temperatura, % monóxido de carbono y presión interior.

De ellas se deduce, por ejemplo, que a 1 atmósfera de presión y 900 °C el 98 % del gas es CO, pero si la presión sube a 20 atmósferas sólo el 70 % es CO y el 30 % CO₂ a la misma temperatura.

1.3.2.1 REACCIONES DE LOS GASES CON LOS SÓLIDOS QUE DESCIENDEN AL CRISOL

Las reacciones fundamentales de este proceso de reducción se muestran en la figura 7, considerando el CO como reductor:

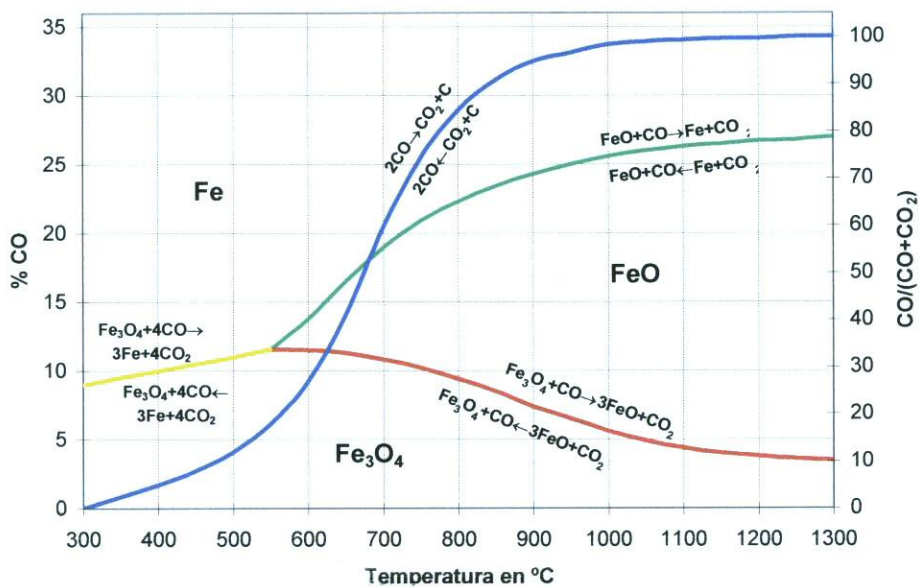


Figura 1.7.- Reacciones fundamentales.

El óxido férrico se transforma en óxido ferroso-férrico según:




a su vez el Fe_3O_4 se transforma en FeO según:



El FeO , a su vez, en presencia de CO da:



También puede producirse:



Estas reacciones son reversibles y según la temperatura a que se produzcan pueden quedar limitadas o producirse de derecha a izquierda, o sea, una oxidación por el CO_2 hacia óxidos superiores.

La reducción con hidrógeno es también posible según las reacciones:



Las curvas de equilibrio se representan en la figura 8 y de ellas se deduce que para concentraciones altas en H_2 , las reacciones se producen en el sentido de izquierda a derecha a temperaturas relativamente bajas, del orden de 600°C o 700°C

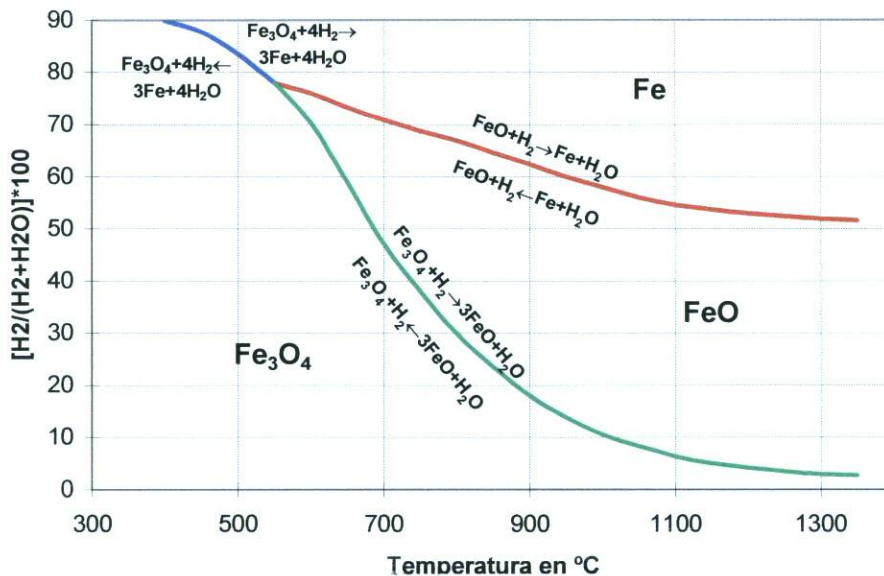


Figura 1.8.- Curvas de equilibrio.

Aparte de otras consideraciones de tipo técnico, la reducción con hidrógeno no se lleva a cabo en la práctica por ser el CO un reductor más económico que el H_2 . También es

posible la reducción con mezcla de CO y H₂. La curva representativa se reproduce en la Figura 1.9.

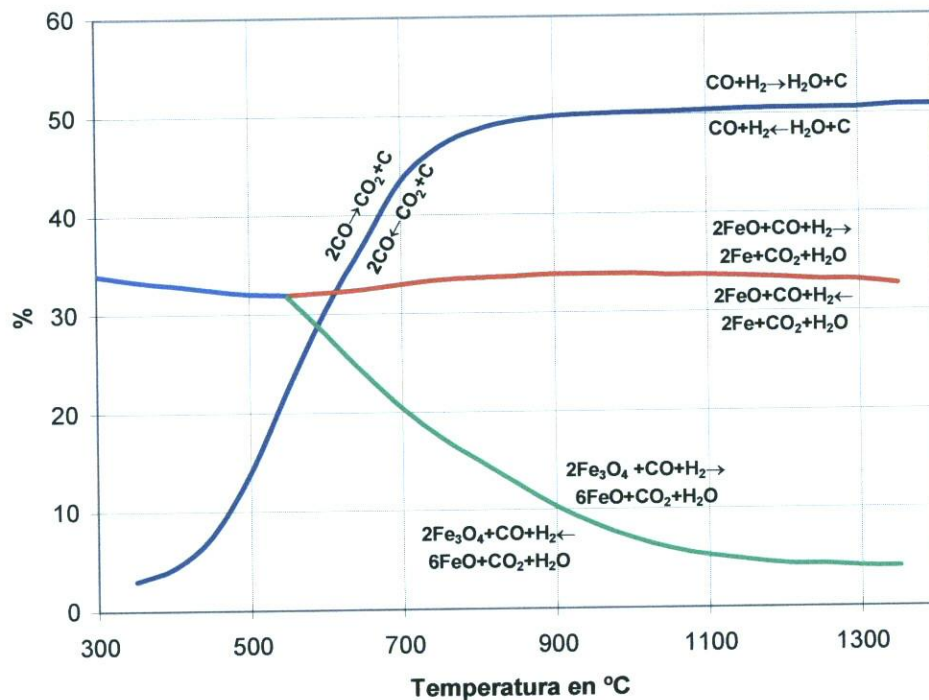






Figura 1.9.- Reducción con mezcla de CO y H₂.

De ella se deduce que existe un gran intervalo de temperaturas, dentro de las cuales el poder reductor de la mezcla se mantiene prácticamente constante a partir de los 600 °C. La mezcla de H₂ y CO es más favorable que la reducción sólo con H₂, pues provoca un descenso de la temperatura y una paralización más o menos acentuada de la reacción, lo que corrige la reducción con CO. En la práctica, los óxidos de hierro presentes en los minerales están combinados con otros óxidos o mezclados con determinadas impurezas. El reductor no está sólo formado por óxido de carbono, sino que también contiene alguna proporción, aunque pequeña, de H₂ como consecuencia de la descomposición de la humedad del viento y tiene siempre un fuerte contenido en N₂ y varía de composición y de temperatura en el proceso. Por otra parte, el coque tiene un contenido en cenizas que también aportan elementos que entran en el proceso.

En zonas relativamente bajas del horno alto, hay reacciones importantes entre el FeO, reducido de los óxidos superiores y la sílice y alúmina que como ganga acompañan a los minerales o contenidas en las cenizas del coque, formándose silicatos de hierro, como hemos dicho anteriormente, más difíciles de reducir. Lo mismo ocurre cuando en el horno alto se cargan minerales muy altos en sílice y, sobre todo, silicatos de hierro. El proceso de reducción de los silicatos no puede realizarse más que en zonas bajas del horno alto y, por tanto, de forma poco económica, pues es necesario que previamente sean descompuestos

los silicatos por la acción de la cal, procedente de la descomposición de la caliza según las reacciones:



El FeO es reducido a su vez por el gran contenido de CO, existente en zonas bajas del horno según:



y a su vez por la inestabilidad del CO₂ a estas temperaturas y profundidades se produce:



Realizándose en definitiva la reducción de los silicatos, como si hubiesen sido reducidos directamente por el C, o sea con gran consumo de combustible.

1.3.3 CONTROL DEL PROCESO DEL HORNO ALTO

Se requieren importantes medidas de control del proceso para garantizar la marcha adecuada del horno alto y de las instalaciones de fabricación de coque y sinterizado con él relacionadas. Se trata de mantener una operación estable del horno y de controlar y proteger el funcionamiento de los equipos instalados. Se utilizan múltiples sensores y equipos de medición y control de los materiales y fluidos de entrada y salida del horno. Concretamente se controla:

- *En las entradas del horno:* materias primas, combustibles principales y auxiliares, viento caliente, oxígeno inyectado al viento, inyección del vapor al viento (control de su humedad), etc.
- *En los equipos del propio horno:* instalación de cribado y carga de materias primas, tragante y sistema de distribución de la carga, presiones y temperaturas en diferentes zonas del horno, niveles de carga, muestras de carga en diferentes áreas, etc.
- *En las salidas del horno:* arrabio y escoria producidos, gas bruto, polvo y lodos recuperados, etc.

Tienen especial importancia los controles de la distribución de la carga en el tragante y de las variables metalúrgicas que determinan el proceso, apoyándose en modelos metalúrgicos, balances térmicos y de materia, además de controles estadísticos de calidad,

inteligencia artificial, etc. Con todo ello se trata de lograr una operación estable del horno alto que redundará en un incremento de la productividad, mejora de la calidad de los productos (arrabio, escoria), aumento de la duración de la campaña del horno alto y reducción de costes (mínimo consumo de coque y de combustibles auxiliares, etc.

Control de materiales y fluidos de entrada y salida del horno alto		
Material/Fluido		Principales variables controladas
Entradas	Q Carga (coque, sinterizado, mineral, etc.)	Pesos, composiciones químicas, granulometrías, características físico-químicas, comportamiento en frío y caliente, ensayos específicos, etc.
	V Viento caliente	Volumen, presión, temperatura, humedad, inyección de oxígeno, etc.
	C Carbón de inyección	Cantidad y distribución, granulometría, composición, propiedades, etc.
Salidas	A Arrabio	Composición, temperatura, cantidad, frecuencia y desarrollo de la colada, etc.
	E Escoria	Composición, cantidad calculada, evolución y desarrollo de colada, etc.
	G Gas	Composición, temperatura, potencia calorífica, caudal calculado y medido, presión, etc.
	Varios (polvo, lodos)	Composición, cantidad, humedad, evolución, etc.

Tabla 1.1- Control de materiales y fluidos de entrada y salida del horno alto.

1.3.4 PRODUCCIÓN, PRODUCTIVIDAD Y CAMPAÑA DEL HORNO ALTO

El control óptimo del proceso con el logro de una marcha estable del horno es uno de los aspectos claves influyentes en la productividad (t/m^3 volumen útil y día), producción (t/año) y duración de la campaña del horno medida en producción total en relación con la dimensión del horno y donde suelen considerarse, por ejemplo, producciones totales por campaña de más de 6 000 t/m^3 de volumen útil. Otros aspectos influyentes en la producción, productividad y duración de campaña son:

- El diseño del horno alto propiamente dicho (perfil, diámetro de crisol y/o volumen útil, etc.).
- La estrategia elegida de obtención de un producto determinado (calidad del arrabio, producción de lingotillo, etc.).
- La calidad y tipo de materias primas empleadas (porcentajes y tipos de sinterizado, de pellets, etc.).

- La calidad del coque y el empleo de combustibles auxiliares como el carbón.
- Las instalaciones auxiliares que permitan una óptima distribución de la carga (tragante), altas temperaturas de soplado (estufas), inyecciones de oxígeno óptimas, trabajo a contrapresión, nivel y regularidad de la marcha, etc.
- La calidad del diseño original de los equipos, como el binomio refractario/refrigeración, así como la fiabilidad de equipos, las tecnologías aplicadas, etc.
- La operación y el mantenimiento adecuados.

Se han desarrollado técnicas especiales para prolongar la duración de la campaña, tales como prácticas de proceso específicas, marchas centrales y no periféricas, sistemas de refrigeración adicionales, inyecciones externas de masas refractarias, mantenimiento específico, etc. La más sofisticada de estas técnicas consiste en la parada del horno con descenso de carga hasta toberas, para su "gunitado" o reparación del refractario y de otros elementos deteriorados, entrando en el horno y/o utilizando robots especialmente diseñados.

1.4 FUNCIONES DEL HORNO ALTO

Las funciones que debe realizar el horno alto son muy complejas si ha de llevarse a cabo el proceso de un modo económico y con el volumen de producción necesario [73]. Una de estas funciones es de *tipo mecánico*, ya que el horno alto debe permitir, de la manera más regular posible, que la carga de materiales sólidos, compuesta por coque, mineral y fundentes, entre por la parte superior del horno y se encuentre con la corriente de gases ascendente bien distribuida y produciendo un contacto íntimo, aunque rápido, con los materiales cargados. Para que esto se produzca de una manera regular, conviene que la carga tenga una gran porosidad y esté muy bien repartida. La mayor o menor porosidad de la carga depende de la forma y dimensiones de los trozos de la carga. La mayor porosidad se obtendría con esferas del mismo tamaño, tangentes y con centros en los vértices de un cubo. En este caso los espacios vacíos dejados entre las esferas representarían el 52,3 % del volumen de éstas. Si las esferas fuesen tangentes, pero con centros en los vértices de un romboedro, los espacios vacíos no serían más que de un 47,7 %.

En la práctica, los trozos de mineral no son esféricos, y lo que es peor, no son iguales, por lo que los tamaños finos colocados entre los huecos dejados por los trozos gruesos pueden bajar fuertemente la porosidad de la carga, de donde se deduce la conveniencia de preparar la carga y clasificarla, dejando los tamaños homogéneos relativamente gruesos y sinterizando los finos, lo que ha sido comprobado en la práctica,

por lo que constituye una tendencia general en la marcha de los hornos altos la preparación previa de la carga. El aparato de carga influye también de una manera importante en la buena distribución de la misma.

La inclinación de la campana de cierre, el diámetro relativo entre la campana y el tragante y el recorrido vertical de la campana, influyen en la forma de distribución de los materiales sólidos en el tragante del horno. También influyen el peso específico de los materiales que se cargan y su ángulo de talud natural. El talud que se forma al cargar los materiales es distinto del talud natural de dichos materiales y se aproxima más al talud natural cuanto mayor es el diámetro del tragante. La relación entre ambos taludes viene dada por la fórmula empírica:

$$\operatorname{tg} \alpha = \operatorname{tg} \alpha_0 - k \cdot \frac{h}{r} \quad (1.15)$$

en la que:

α : es el talud en el horno:

α_0 : es el talud natural.

h : la altura de caída.

r : radio del tragante.

k : una constante que tiene en cuenta la naturaleza del material y, entre otras cosas, la absorción del golpe de caída contra las paredes del horno.

En los hornos grandes, lo corriente es que la carga se presente más alta en los bordes que en el centro, que el mineral forme cuñas de más altura en los bordes que en el centro y que, por el contrario, el coque forme cuñas de más altura en el centro.

Mecánicamente, además, el horno alto debe distribuir los gases de tal manera que baje la carga regularmente y sin formar zonas de paso preferente, que daría origen a dificultades en la marcha. Tampoco debe producirse preferencia de paso por las paredes o por el centro, para lo que dentro de ciertos límites deberá poder controlarse la distribución de materiales más gruesos o más finos en el centro o en las paredes. Por otro lado, como la carga al descender va sufriendo modificaciones de composición, de temperatura y de volumen, el horno alto debe favorecer todos estos cambios y permitir el descenso regular de la carga, la formación de escoria, la evacuación de ésta y la evacuación del arrabio por la parte inferior y la de los gases producidos por el tragante. Otra función importante que debe cumplir el horno alto es la de intercambiador de calor.

1.5 EL ARRABIO, LA ESCORIA Y SUS FORMAS DE TRATARLOS

1.5.1 EL ARRABIO Y SU MANEJO

El arrabio que sale del horno alto, es un material complejo, cuya composición química puede variar dentro de amplios límites y cuya estructura al solidificarse varía no solamente con la composición química, sino también con la velocidad de enfriamiento [73]. El arrabio producido en los hornos altos puede ser apropiado para servir de base a la fabricación de piezas fundidas según su composición, las mezclas que se realicen y las condiciones de fabricación, o puede servir para su conversión en acero por procesos que se adapten a la composición del arrabio.

Debido a lo que ocurre con cada uno de los elementos que entran en la carga del horno alto, se puede afirmar que el operador del horno alto, sólo puede controlar la composición del arrabio en lo que se refiere al Si, Mn y S, siendo los demás elementos prácticamente incontrolables y dependientes de la composición de la carga. Entre éstos es fundamental, por influir decisivamente en el proceso de fabricación, que se elija el fósforo (P). En cuanto al otro componente fundamental del arrabio, el carbono (C), siempre se produce en el horno alto la saturación del arrabio y, por tanto, el contenido en éste depende del contenido de los demás elementos que influyen en el grado de saturación en C del arrabio y en su forma de presentarse al solidificarse con mayor o menor proporción de grafito o de carburo de hierro o cementita, en lo que influyen en uno u otro sentido el Si, el Mn y el P. En la marcha industrial de los hornos altos se distinguen las siguientes principales calidades de arrabio:

- Arrabios con contenido en Si altos, de 1,5 % a 2,5 %; Mn entre 0,5 % y 2 % y P < 0,08 %.
- Arrabios con análisis muy parecidos al anterior, pero con más P, que puede oscilar entre 0,1 % y 0,7 %.
- Arrabios con contenido en Si inferior al 1 %; Mn, entre el 1 % y el 2 %; P, entre el 0,3 % y el 0,6 %; S < 0,045 %; C, el 4 %; resto, Fe.
- Arrabios con contenido en Si inferior al 1 %; Mn, del 1 % al 2 %; P, del 1,5 % al 2,5 %; S < 0,06 %; C, el 4 %; resto, Fe

CAPÍTULO 2

REDES NEURONALES

2. INTRODUCCIÓN A LAS REDES NEURONALES

Hasta el presente las computadoras han resuelto numerosos problemas desde una simple base de datos hasta un sistema SCADA. Pero aún así existe otra parcela en la cual la revolución informática no ha entrado todavía de lleno: sistemas ambiguos o imprecisos, toma de decisiones, etc. Una característica común de este tipo de problemas es que difícilmente se pueden solucionar utilizando sistemas secuenciales. La solución se encamina hacia arquitecturas en paralelo.

Un claro ejemplo está en nuestra visión. ¿Cómo es posible que aunque el tiempo de procesamiento de nuestras neuronas esté en el orden de los milisegundos nuestro cerebro "vea" fotos y reconozca los objetos que aparecen en ellas mientras que un súper ordenador con tiempos en el orden de los nanosegundos no sea capaz de verlo? La respuesta se halla en un paralelismo masivo y una alta interconectividad propia de los sistemas neurobiológicos. En este contexto han aparecido las redes neuronales. Se copia la forma de actuar de nuestro cerebro con la idea de aplicarla a este nuevo tipo de problemas. Así pues, desde aquí en adelante en vez de estudiar el modelo neurológico humano detallaremos los tipos de R.N.s usados en el desarrollo de esta Tesis.

2.1 TIPOS DE REDES NEURONALES

Las redes neuronales se pueden dividir en dos grandes grupos según que su tipo de aprendizaje sea supervisado o no-supervisado. El primero de ellos se distingue porque la red necesita un conjunto de entrada y un conjunto de salidas asociadas. Se introduce una entrada a la red y se halla el error respecto a la salida real. La corrección de los pesos se hará a partir de este error. El entrenamiento se basará en minimizar dicho error y se considerará acabado cuando sea menor que una cantidad muy pequeña (ϵ). En el aprendizaje no supervisado se tienen unos patrones de entrada pero no sus salidas. El objetivo de la red es agrupar los vectores de entrada mediante un criterio de similitud en unos ciertos patrones de salida. El entrenamiento finaliza cuando los pesos sufren cambios muy pequeños en cada iteración. El Perceptrón, multicapa y las redes LVQ poseen un aprendizaje supervisado mientras el modelo de Kohonen, la red de Hopfield y las arquitecturas ART son del tipo no supervisado.

2.1.1 PERCEPTRÓN MULTICAPA

Una de estas redes está compuesta por una capa de entrada, varias capas intermedias u ocultas y una capa de salida. Los pesos, las entradas o la polarización son opcionales, pero se suelen añadir para evitar problemas de ‘offset’.

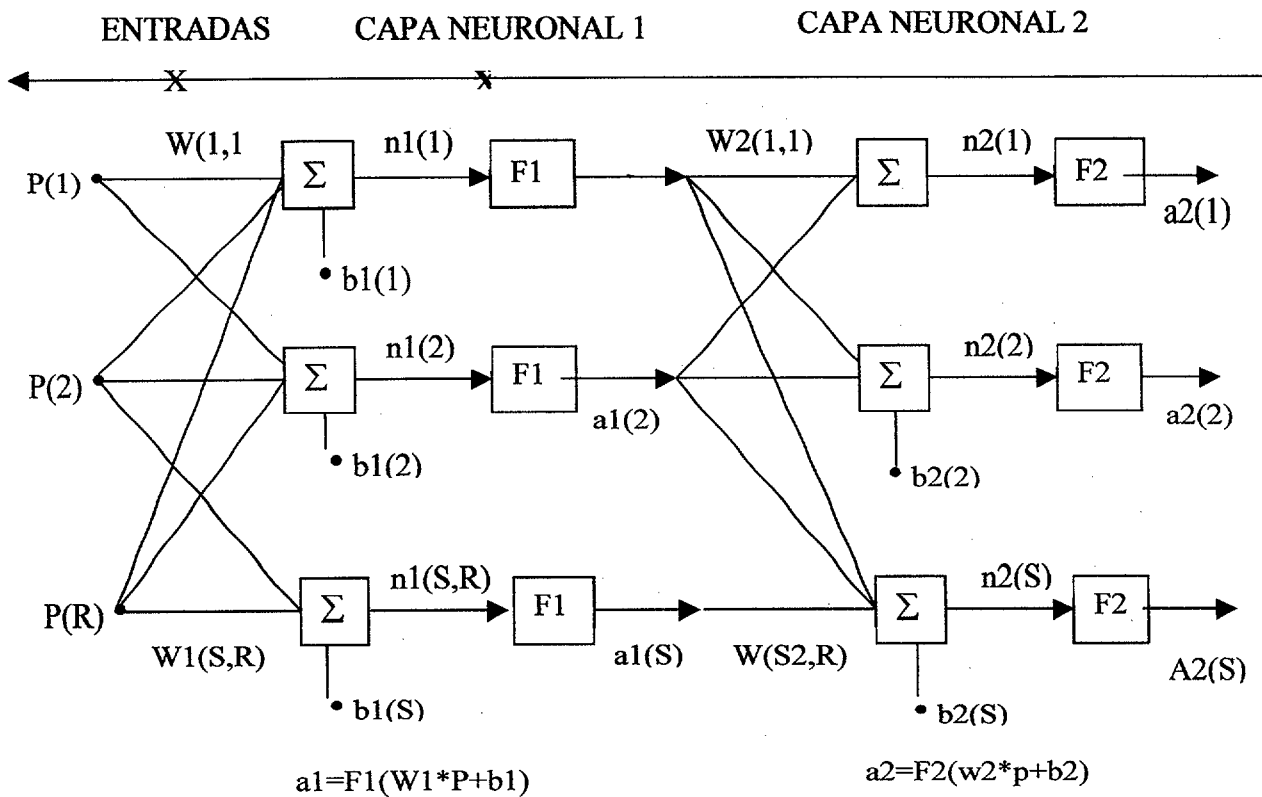


Figura 2.1.- Esquema de Perceptrón multicapa.

El método “backpropagation” sigue una norma de corrección de los pesos denominada norma Delta que los actualiza con idea de minimizar el error cuadrático medio entre la salida real y la suministrada por la red. Dichos errores se propagan hacia atrás en el sentido de que primero se modifican los pesos de las neuronas de salida y luego de las capas intermedias y al final los de la capa de entrada. Se determina la dirección de cambio de los pesos calculando el gradiente del error respecto a los pesos y yendo en el sentido contrario hasta que encuentra un mínimo. Los pasos a dar para programar el algoritmo de backpropagation son los siguientes:

- Introducir el vector de datos a las neuronas de la capa de entrada:

$$P^1 = (P(1), P(2), \dots, P(N))$$

- Calcular valores netos \$n\$ de entrada a las neuronas de las capas ocultas:

$$n_{pj}^h = \sum_{i=1}^h w_{ji}^h \cdot P_{pi} + \theta_j^h$$

j = número de neuronas.

h = cantidad de neuronas en la capa p .

N = número de unidades de entrada.

θ = entrada de polarización, de valor unitario.

- Los valores de salida de la capa oculta se calculan por:

$$i_{pj} = F_j^h(n_{pj}^h)$$

- Y se repite con la capa de salida:

$$n_{pk}^0 = \sum_{j=1}^L w_{pj}^0 \cdot i_{pj} + \theta_k^0$$

- Se calculan los valores de salida de la capa de salida

$$o_{pk} = F_k^0(n_{pk}^0)$$

- Los errores en la capa de salida se calculan por:

$$E_{pk}^0 = (y_{pk} - o_{pk}) \cdot F_k^0(n_{pk}^0)$$

- A continuación se calculan los errores para las capas ocultas:

$$E_{pj}^h = F_j^h(n_{pj}^h) \cdot \sum_k \delta_k^0 w_{kj}^0$$

- Se actualizan los pesos en la capa de salida:

$$w_{kj}^0(t+1) = w_{kj}^0(t) + \eta \cdot \delta_{pk}^0 \cdot i_{pj}$$

- Actualizar pesos en las capas ocultas:

$$w_{ji}^h(t+1) = w_{ji}^h(t) + \eta \cdot \delta_{pj}^h \cdot p_i$$

η es un parámetro que determina la velocidad del aprendizaje. Suele tomar valores entre 0.01 y 0.25.

η η

- Posteriormente se calcula el error total:

$$E_p = \frac{1}{2} \sum_{k=1}^M \delta_{pk}^2$$

- El aprendizaje finaliza cuando el error es menor que una cierta cantidad muy pequeña, $E_p < \varepsilon$.

- Este algoritmo es más usado en la práctica dada su habilidad para aproximar funciones no-lineales. Sin embargo, presenta una serie de dificultades entre las que se pueden citar:

- Posible caída en un mínimo local en el que el proceso quedaría bloqueado. La solución pasa por inicializar de nuevo las entradas o cambiar el número de nodos de la capa oculta.

- La convergencia es lenta en situaciones de "valles". Esto se soluciona añadiendo un momento que acelere el método. De esta manera:

$$w_{kj}^0(t+1) = w_{kj}^0(t) + \eta \cdot \delta_{pk}^0 \cdot i_{pj} + \alpha \cdot \Delta_p w_{kj}^0(t-1)$$

El valor de α se sitúa entre 0 y 1 y su función es añadir el efecto de los cambios pasados a la actual dirección.

- La elección del tamaño de la red, constantes y demás parámetros puede ser difícil.

Lo mejor es seguir un método de ensayo y error. Sistemas grandes podrían tener tiempos de convergencia sumamente largos.

2.1.2 REDES COMPETITIVAS

Se parte de una red denominada Red de Hamming. Existe una técnica que permite usar esta red neuronal para reconocimiento de patrones. Esta técnica requiere que los vectores prototipo sean conocidos de antemano e incorporados a la red como filas de la matriz de pesos. Las redes que se van a analizar tienen una estructura muy similar a la Red de Hamming, sin embargo, utilizan reglas de aprendizaje asociativo para, de forma adaptativa, aprender a clasificar patrones. Estos tres tipos de redes son: Redes Competitivas, Mapas Autoorganizativos, y Redes LVQ.

La Red de Hamming es uno de los ejemplos más simples de red competitiva. Las neuronas de la capa de salida compiten con las otras para determinar el ganador, y este indica qué patrón prototipo es el más representativo del patrón de entrada. La competición se implementa con inhibición lateral, un conjunto de conexiones negativas entre las neuronas de la capa de salida.

2.1.3 RED COMPETITIVA DE HAMMING

Se van a ver algunos de los conceptos fundamentales de esta red.

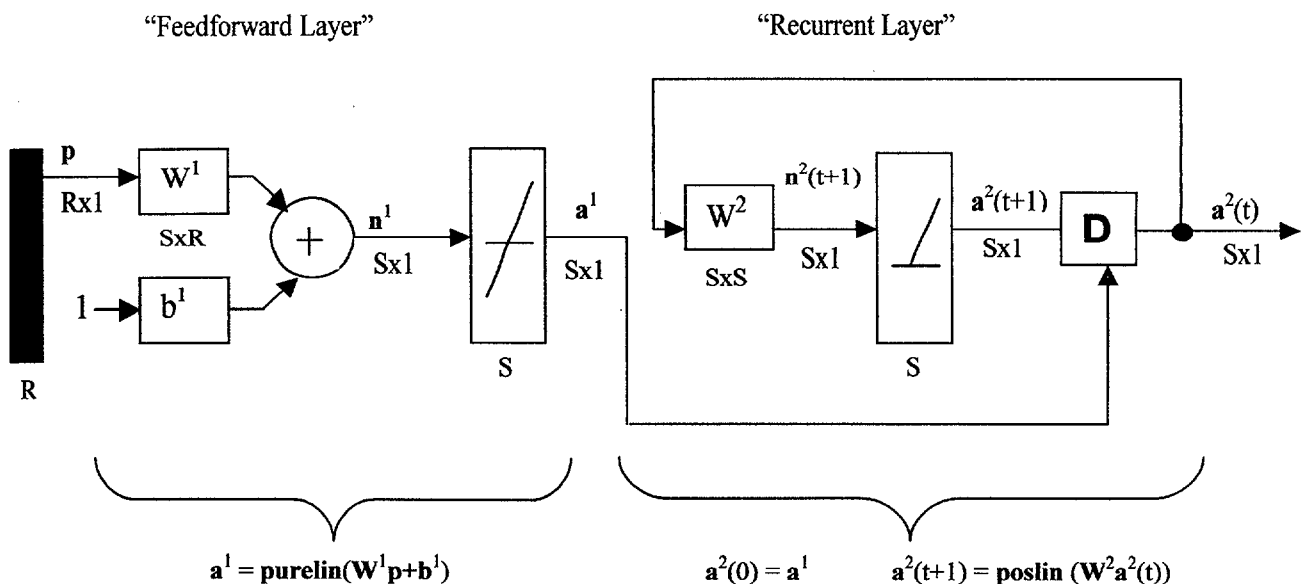


Figura 2.2.- Red Hamming (Hamming Network)

La Red Hamming consta de dos capas. La primera de ella realiza una correlación entre el vector de entrada y el vector prototipo. La segunda capa realiza la competición para determinar cual de los vectores prototipo está más cerca del vector de entrada. Permite la clasificación de patrones múltiples. Esto es lo que realiza la Red de Hamming.

Sin embargo en la red competitiva de Hamming la segunda capa de neuronas de la Red de Hamming se dice que está en competición, porque cada neurona se excita a sí misma e inhibe al resto. Para simplificar el resto de las ecuaciones se define la función de transferencia que hace el trabajo de la capa recurrente competitiva:

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

Esta red funciona buscando el índice i^* de la neurona con la entrada a la red mayor y pone su salida a uno (siempre buscando el índice más bajo). Todas las otras salidas se ponen a cero.

$$a^i = \begin{cases} 1 & \text{si } i=i^* \\ 0 & \text{si } i \neq i^* \end{cases} \quad \text{donde } n^{i^*} \geq n_i, \forall i, \text{ y } i^* \leq i, \forall n_i = n_{i^*}$$

Reemplazando la capa recurrente de la Red de Hamming con la función de transferencia competitiva en la primera capa es más fácil entender el funcionamiento de las siguientes Redes.

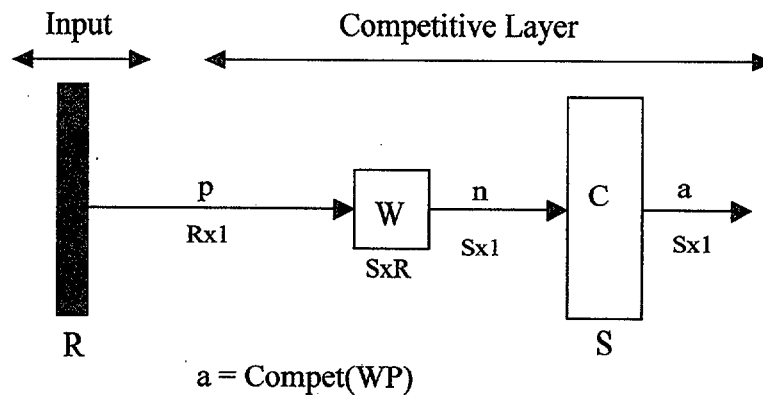


Figura 2.3.- Red competitiva ('Competitive Layer')

Como en la Red de Hamming los vectores prototipo se almacenan en filas de W . La entrada a la red n calcula la distancia entre el vector entrada p y el prototipo W , (suponiendo que los vectores están normalizados a longitud L). La entrada a la red n , de cada neurona i es proporcional al ángulo θ_i , formado entre p y el vector prototipo W :

$$n = WP = \begin{bmatrix} w_1^T \\ w_2^T \\ \dots \\ w_s^T \end{bmatrix} P = \begin{bmatrix} w_1^T P \\ w_2^T P \\ \dots \\ w_s^T P \end{bmatrix} = \begin{bmatrix} L^2 \cos \theta_1 \\ L^2 \cos \theta_2 \\ \dots \\ L^2 \cos \theta_s \end{bmatrix}$$

La función de transferencia competitiva asigna una salida 1 a la neurona cuyo vector peso apunta en la dirección más cercana al vector de entrada

$$a = \text{Compet}(WP)$$

2.1.4 MAPAS AUTOORGANIZADOS

Para tratar de emular la actividad de los sistemas biológicos, Kohonen diseñó la siguiente simplificación: su Red Autoorganizativa determina primero la neurona ganadora i^* usando los procedimientos de la red competitiva. Después, los pesos que se encuentran dentro de una cierta vecindad de la neurona ganadora son modificados por la Regla de Kohonen.

$$w_i(q) = w_i(q-1) + \alpha(p(q) - w_i(q-1)) + \alpha p(q) = (1-\alpha)w_i(q-1) + \alpha p(q), \quad i \in N_{i^*}(d)$$

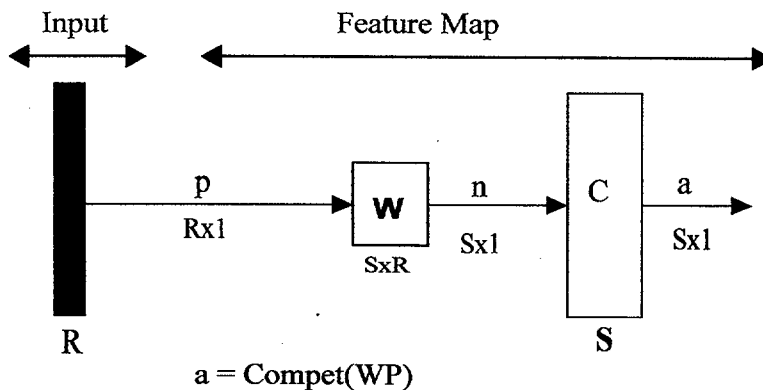


Figura 2-4: Mapa Autoorganizado.

Donde la vecindad $N_{i^*}(d)$ contiene los índices para todas las neuronas que están dentro de un radio d de la neurona ganadora i^* :

$$N_{i^*}(d) = j, \quad (d_{ij} \leq d)$$

Cuando se muestra a la red el vector p , los pesos de la neurona ganadora y las vecinas se mueven hacia p . El resultado es que, después de varias presentaciones, las neuronas vecinas han aprendido vectores similares. Si se trata de una sola dimensión, cada neurona tendrá sólo dos vecinos dentro de un radio de 1. Los mapas tienen también la ventaja de poderse adaptar al espacio de entrada, teniendo unas dimensiones determinadas. Para una región de entrada bidimensional, la red que se debe utilizar para clasificar también debe ser bidimensional con agrupamientos de $n \times n$ neuronas. Cada nodo es una neurona y la mayor parte de ellos se encuentran en el interior de la región del espacio de entrada y ocupan el espacio de una manera uniforme. Si se tiene un espacio de entrada tridimensional y se utiliza una red bidimensional, esta última se adapta al espacio de entrada pero no puede aproximar la tercera dimensión nada más que mediante su valor medio.

Kohonen propuso distintos conceptos de distancias, y para ello estudió vecindades rectangulares y hexagonales para conseguir una implementación más eficiente. A pesar de esto normalmente las características de aprendizaje de la red no son muy sensibles a la forma exacta. Cuando el vector p se muestra a la red, los pesos de la neurona ganadora y las vecinas se mueven hacia p . El resultado es que, después de varias presentaciones, las neuronas vecinas han aprendido vectores similares.

Cabe mencionar que las neuronas de la red pueden ser agrupadas en las dimensiones que se deseen. Si se trata de una sola dimensión, cada neurona tendrá sólo dos vecinos dentro de un radio de 1. Los mapas tienen también la ventaja de poder adaptarse al espacio de entrada, teniendo unas dimensiones determinadas. Para una región de entrada bidimensional, la red que se debe usar para clasificar también debe ser bidimensional con agrupamientos de $n \times n$ neuronas. Cada nodo es una neurona y la mayor parte de ellos se encuentran en el interior de la región del espacio de entrada y ocupan el espacio de una manera uniforme.

El aprendizaje del espacio de entrada también es función del número de iteraciones que se realicen. Si se dispone de un espacio de entrada formado por vectores de entrada aleatorios que están limitados, por ejemplo, a un plano cuadrado, después del entrenamiento, la distribución de las neuronas debe ser uniforme a lo largo de todo el espacio. El proceso que ocurre hasta conseguir esto es como sigue: cada vez que un vector peso es presentado la neurona con el vector peso más cercano ganará la competición y la neurona ganadora y sus vecinas se moverán hacia dicho vector.

2.1.5 REDES L.V.Q ('LEARNING VECTOR QUANTIZATION') Y SUS MEJORAS

Esta red utiliza dos tipos de aprendizaje: supervisado y no supervisado para formar las clasificaciones. Como puede verse en la figura 2-5, cada neurona de la primera capa se

asigna a una clase. Cada clase se representa con una neurona de la segunda capa. El número de neuronas de la primera capa, S^1 será siempre mayor que el número de neuronas de la segunda capa, S^2 y normalmente bastante mayor.

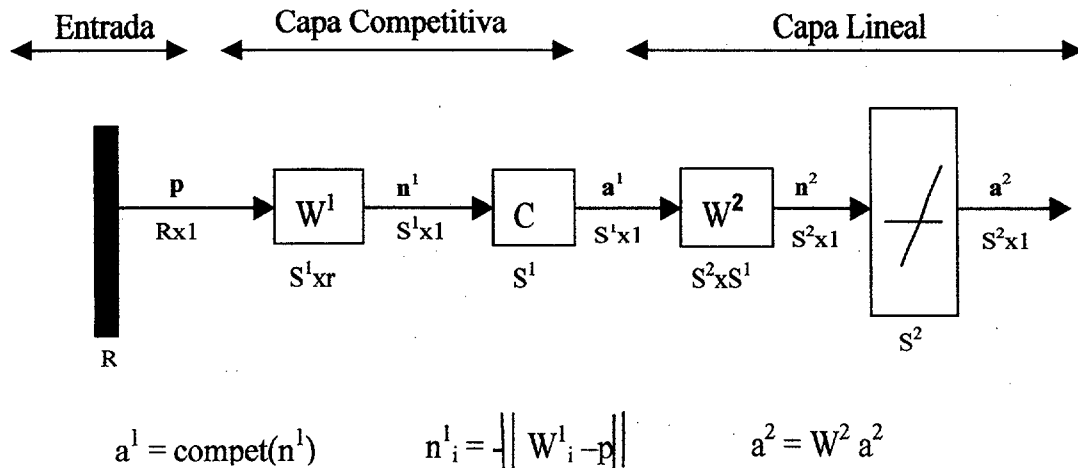


Figura 2-5.- Red L.V.Q

Como en las redes competitivas, cada neurona de la primera capa aprende un vector prototipo, que permite clasificar una región del espacio de entrada. La distancia al vector de entrada se calcula mediante la distancia euclídea. La entrada de la red de la primera capa de la LQV será:

$$n^1_i = -\|W^1_i - p\|$$

La salida de la primera capa de la LQV es:

$$a^1 = \text{compet}(n^1)$$

De esta manera, la neurona cuyo peso se encuentre más próximo al vector de entrada dará 1 como salida, y el resto 0. La red LQV se comporta como la red competitiva, pero la interpretación es diferente. En la red competitiva la neurona ganadora indicaba a que clase pertenecía el vector de entrada. En la red LQV, la neurona ganadora indica la subclase más que la clase. Puede haber diferentes subclases dentro de cada clase.

La segunda capa de la red se usa para combinar las subclases dentro de una clase. Esto se puede realizar con la matriz W^2 . Las columnas de W^2 representan las subclases, y las filas las clases. W^2 Tiene sólo un 1 en cada columna, con los otros elementos cero. La fila en la que se encuentra el 1 indica cual es la clase a la que la subclase pertenece.

$(w_{ki}^2=1)$ \implies subclase i es parte de la clase k .

El proceso de combinar las subclases para formar una clase permite a la LQV crear saltos de clase complejos. La LQV resuelve el problema de trabajar con regiones del espacio convexas. Aunque esta red trabaja bien ante multitud de problemas, tiene dos limitaciones. La primera, como las redes competitivas, es que ocasionalmente una neurona oculta puede tener un valor inicial que nunca gana la competición. El resultado es una neurona muerta que no hace nada útil. Este problema se resuelve con el mecanismo de consciencia.

En segundo lugar, dependiendo de cómo se inicialicen los vectores peso, un vector peso tendrá que viajar a través de una región perteneciente a una clase que no representa. Los pesos de esa neurona serán rechazados por los vectores de la región que debe cruzar, y así nunca podrá clasificar adecuadamente la región que le atrae. Esto se puede resolver aplicando una modificación a la regla de Kohonen.

Si la neurona ganadora en la capa oculta clasifica el vector de entrada incorrectamente, se mueve su vector peso hacia fuera del vector de entrada, como antes. Sin embargo, se ajustan los pesos de la neurona más cercana al vector de entrada que lo clasifique correctamente. Los pesos de esta segunda neurona deben moverse hacia el vector de entrada.

Cuando la red clasifica correctamente el vector de entrada, los pesos de una sola neurona se mueven hacia el vector de entrada. Sin embargo, si el vector de entrada se clasifica de forma incorrecta, los pesos de dos neuronas son modificados, un peso se mueve hacia el vector de entrada y el otro hacia fuera.

Hasta aquí se han descritos las redes más usadas tanto en esta memoria como en distintas aplicaciones que versan sobre el proceso de producción de hierro y acero.

2.2 SISTEMAS BASADOS EN REGLAS BORROSAS

Al igual que las RNA, los **Sistemas Basados en Reglas Borrosas (SRB)** [57], también son aproximadores universales. Los SRB tienen la ventaja de que el conocimiento que manejan está representado en un modo perfectamente asimilable por el ser humano, las **reglas borrosas**. Estas reglas, en general, representan de modo natural las relaciones de causalidad entre entradas y salidas, correspondientes a la estructura lingüística usual “*Si ... Entonces ...*”. Las reglas borrosas tienen la ventaja adicional de permitir un tratamiento adecuado del conocimiento vago o incierto. Dentro de las clases de controladores borrosos que son aproximadores universales están los controladores de Sugeno [36] que utilizan reglas del tipo:

R_i : SI x_1 es A_i^1 y x_2 es A_i^2 y ... y x_t es A_i^t ENTONCES y es $p(x_1, \dots, x_t)$ (2.4)

Donde $p(x_1, \dots, x_t)$ es una función lineal de las entradas.

Cuando las funciones de activación de una RNA son continuas, la función que calcula ésta, F , es continua. Por tanto, una RNA se puede aproximar mediante una SRB. Recíprocamente, una RNA puede aproximar un SRB continuo. De este modo es fácil concluir que las RNA que se han descrito y los SRB son equivalentes. Basada en esta equivalencia entre RNA y SRB es inmediata la idea de emplear un sistema híbrido que use los dos paradigmas para realizar la tarea de adquisición del conocimiento. Una de las más interesantes es la que trata de extraer el conocimiento obtenido por una red tras el aprendizaje almacenado de forma distribuida en los pesos de sus conexiones. Esto no sólo suministraría un método automatizado y eficaz de adquisición de conocimiento, sino que además proporcionaría una interpretación del modo en que operan y aprenden las RNA.

2.3 SISTEMAS DE INGENIERÍA COMO COMBINACIÓN DE LA INFORMACIÓN NUMÉRICA Y LINGÜÍSTICA

Una Aproximación de Sistemas Borrosos Adaptativos.

En la mayoría de los sistemas hay dos fuentes importantes de información [18]:

Los sensores, que proporcionan las medidas numéricas de las distintas variables, lo que se denomina **información numérica**.

Los operadores de planta, que proporcionan instrucciones y descripciones lingüísticas sobre el sistema, y se denomina **información lingüística**.

La información numérica se representa con números (por ejemplo 0,25, 1,44) mientras que la información lingüística se representa con palabras como: pequeño, grande muy grande, etc. Las aproximaciones convencionales de la ingeniería sólo pueden utilizar la información numérica y tienen, por tanto, grandes dificultades para poder incorporar la información lingüística. Como la mayoría de los conocimientos que posee el ser humano se representan en términos lingüísticos, su incorporación a los sistemas de ingeniería de una forma sistemática y eficiente es muy importante. Hay al menos tres razones de por qué la información lingüística se representa normalmente en términos borrosos.

La primera, es que es más conveniente y eficiente transmitir nuestro conocimiento en términos borrosos. Esto es comprensible porque si se insiste en utilizar sólo términos numéricos (*crisp*), se deben tener primero las definiciones exactas de estos términos. Esto, sucesivamente, puede dar como resultado una cadena de definiciones, y un procedimiento muy ineficiente que claramente no ocurre en la realidad. Segundo, nuestro conocimiento

sobre muchos problemas es esencialmente borroso. Por ejemplo, cuando se descubre una nueva teoría, ocurre con frecuencia que se sabe “algo” sobre ella, por ejemplo, su causa, los conceptos básicos, las ventajas, los inconvenientes, etc. pero también ocurre que no se está seguro sobre algunos de sus detalles. Si hay que explicársela a otra persona, lo más normal es que sólo capte una descripción borrosa y superficial de la teoría. Lo importante es que aunque la descripción no sea muy clara, se puede llegar a obtener bastante bien el propósito que se buscaba con esta explicación. Tercero, muchos sistemas son demasiados complejos para poder ser descritos en términos precisos. Por ejemplo, el conocimiento sobre un proceso químico complejo sólo puede representarse en términos borrosos, por ejemplo, “Si la temperatura es elevada, entonces la reacción es intensa”. La característica relevante aquí es que aunque este tipo de información lingüística no es preciso, proporciona información importante sobre el sistema y algunas veces puede ser la única fuente de información. Por estas razones, se debería utilizar esta información borrosa en investigaciones científicas.

Un **sistema borroso adaptativo** se define como un sistema de lógica borrosa que lleva incorporado un algoritmo de entrenamiento, donde el sistema de lógica borrosa se construye a partir de un conjunto de reglas ‘Si-Entonces’ borrosas utilizando los principios de la lógica borrosa, y el algoritmo de entrenamiento ajusta los parámetros y las estructuras del sistema de lógica borrosa basándose en información numérica. Los sistemas adaptativos borrosos se pueden considerar como sistemas de lógica borrosa en los que las reglas se generan automáticamente mediante un entrenamiento. Hay dos formas de combinar la información numérica y lingüística utilizando sistemas adaptativos borrosos:

- Utilizar la información lingüística para construir un sistema de lógica borrosa inicial, y a continuación ajustar los parámetros de este sistema creado basándose en información numérica. El sistema de lógica borrosa final se construye, por tanto, basándose en ambos tipos de información (tanto numérica como lingüística).
- Utilizar información numérica y lingüística para construir dos sistemas de lógica borrosa separados y a continuación se realiza un promedio entre ambos para obtener el sistema de lógica borrosa final.

2.4 ANFIS: Sistema de Inferencia Borroso basado en redes adaptativas

El modelado de sistemas basados en herramientas matemáticas convencionales (por ejemplo, las ecuaciones diferenciales) no se adapta bien cuando tiene que ocuparse de sistemas mal definidos e inciertos. Por contra, un sistema de inferencia borroso que utiliza reglas ‘Si-Entonces’ borrosas puede modelar los aspectos cualitativos del conocimiento humano y los procesos de razonamiento sin el empleo de análisis cuantitativos precisos. A este “modelado borroso” o de “identificación borrosa”, que fueron estudiados sistemáticamente por Takagi y Sugeno [38], se le han encontrado numerosas aplicaciones

prácticas en control [36], en predicción y en inferencia. Sin embargo, hay algunos aspectos básicos de esta investigación que son necesarios para poder entenderlo mejor. Más específicamente:

- Los métodos no comunes existen para transformar el conocimiento humano o la experiencia en la base de reglas y en la base de datos de un sistema de inferencia borroso.
- Se necesitan métodos efectivos para afinar las funciones de pertenencia (MFs) así como minimizar la medida del error de salida o maximizar el orden de funcionamiento.

Con esta perspectiva, se sugiere una nueva arquitectura que encaja el sistema de inferencia borroso en la estructura de las redes adaptativas llamada “**Sistema de Inferencia borroso basado en redes adaptativas**” o simplemente – en inglés- “ANFIS” [21], que puede servir como una base para la construcción de un conjunto de reglas ‘ Si-Entonces’ borrosas, con sus apropiadas funciones de pertenencia, para generar los pares de entrada / salida estipulados.

2.5 REGLAS “SI-ENTONCES” BORROSAS

Las reglas “Si-Entonces borrosas” u oraciones condicionales borrosas son expresiones de la forma “SI A, ENTONCES B”, donde A y B son los nombre de conjuntos borrosos [51] caracterizados mediante sus funciones de pertenencia apropiadas. Debido a su forma concisa, las reglas borrosas se emplean frecuentemente para captar los modos imprecisos de razonamiento que desempeñan un papel esencial en la habilidad humana de tomar decisiones en un entorno de incertidumbre e imprecisión. Un ejemplo que describe un hecho simple es el siguiente:

Si la presión es alta, entonces el volumen es pequeño.

Donde “*presión*” y “*volumen*” son variables lingüísticas [53]; y “*alta*” y “*pequeño*” son valores lingüísticos o los nombres que caracterizan las funciones de pertenencia. Otra forma de regla borrosa, propuesta por Takagi y Sugeno [37], tiene los conjuntos borrosos incluidos sólo en la premisa (antecedente). Utilizando la regla borrosa de Takagi y Sugeno se puede describir la fuerza resistente de un objeto en movimiento de la siguiente manera:

Si la velocidad es alta, entonces la fuerza = $k(\text{velocidad})^2$

2.6 ARQUITECTURA DE SISTEMAS DE INFERENCIA BORROSOS

Los sistemas de inferencia borrosos son también conocidos como sistemas basados en reglas borrosas, modelos borrosos, memorias asociativas borrosas (FAM) o controladores

borrosos estos últimos cuando se utilizan para controlar. Básicamente un sistema de inferencia borroso está compuesto de cinco bloques funcionales (Figura 2.6):

- Una *base de reglas* que contiene un número de reglas Si-Entonces borrosas.
- Una *base de datos* que define las funciones de pertenencia de los conjuntos borrosos utilizados en las reglas borrosas.
- Una *unidad de toma de decisión* que realiza las operaciones de inferencia en las reglas.
- Un *fuzzificador*, que transforma las entradas numéricas (*crisp*) en grados de similitud a través de valores lingüísticos.
- Un *defuzzificador*, que transforma los resultados borrosos de la inferencia en salidas numéricas (*crisp*).

Normalmente, la base de reglas y la base de datos se denominan de forma conjunta *base de conocimiento*.

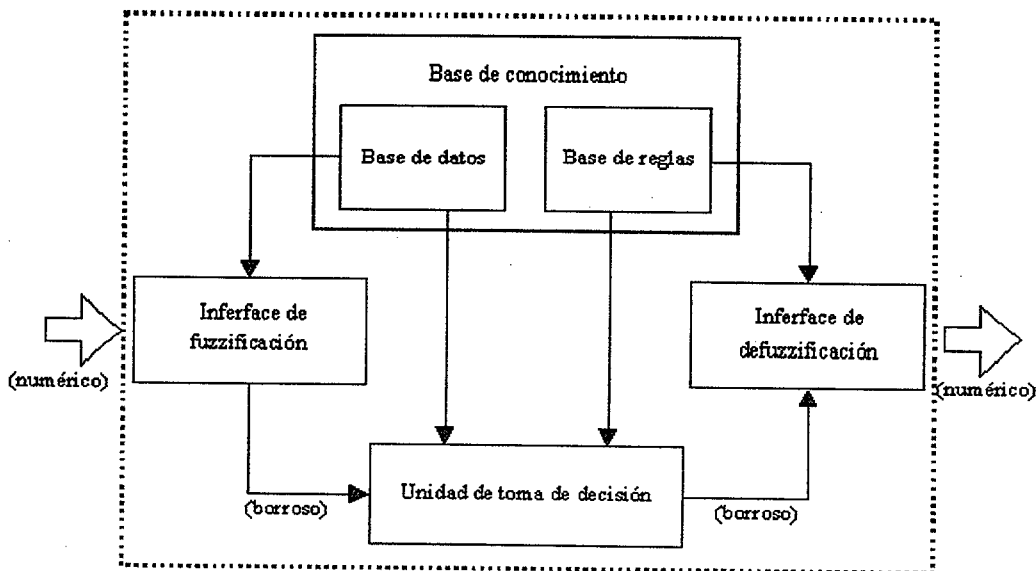


Figura 2.6.- Arquitectura de Sistema de Inferencia Borroso.

Los pasos que realiza el razonamiento borroso (operaciones de inferencia sobre las reglas borrosas) mediante los sistemas de inferencia borrosos son:

1. Comparar las variables de entrada con las funciones de pertenencia en el antecedente para obtener los valores de pertenencia (o medidas de compatibilidad) de cada valor lingüístico (este paso se denomina frecuentemente “fuzzificación”).
2. Combinar mediante un operador T-norma específico (normalmente “producto” o “min”) los valores de pertenencia en el antecedente para obtener el “peso” de cada regla.
3. Generar la consecuencia calificada (ya sea borrosa o numérica) de cada regla, dependiendo del peso.

4. Unir las consecuencias calificadas para producir una salida concreta (Este paso se denomina “defuzzificación”).




Figura 2.7.- Reglas Si-Entonces borrosas y mecanismos de razonamiento borroso empleados normalmente.

Dependiendo de los tipos de razonamiento borrosos y de las reglas borrosas empleadas, la mayoría de los sistemas de inferencia borrosos se pueden clasificar en tres tipos:

Tipo 1: La salida global es una media ponderada de las salidas numéricas de cada una de las reglas inducidas por sus pesos (el producto o el mínimo de los grados de pertenencia con la premisa) y las funciones de pertenencia de la salida. Estas últimas deben ser funciones monótonas.

Tipo 2: La salida global deriva de la aplicación del operador “máximo” a las salidas borrosas calificadas (cada una de ellas es igual al mínimo del peso y de la función de pertenencia de la salida de cada regla). Se han propuesto varios tipos de operadores para elegir el valor concreto final basado en la salida borrosa global. Algunos de éstos son el centroide del área, la bisectriz del área, la media de los máximos, el criterio del máximo, etc.

Tipo 3: Se utilizan las reglas borrosas de Takagi y Sugeno [37]. La salida de cada regla es una combinación lineal de las variables de entrada más un término constante, y la salida final es la media ponderada de las salidas de cada regla.

2.6.1 ARQUITECTURA DE SISTEMA DE INFERENCIA BORROSO BASADO EN UNA RED ADAPTATIVA. ARQUITECTURA DEL ANFIS


Funcionalmente, no hay casi restricciones sobre las funciones nodales de una red adaptativa excepto que tienen que ser diferenciables a trozos. Estructuralmente, la única limitación de la configuración de la red es que debería ser del tipo propagación hacia delante. Debido a estas mínimas restricciones, las aplicaciones de la red adaptativa son inmediatas e inmensas en varios campos. A continuación, se propone una clase de redes adaptativas que son funcionalmente equivalentes a los sistemas de inferencia borrosos. La arquitectura propuesta se denomina ANFIS, siglas en inglés de “Sistema de Inferencia Borroso basado en una Red Adaptativa” [21].

Para simplificar, se supone un sistema de inferencia borroso que tiene dos entradas (x_1 y x_2) y una salida (z). Se supone también que la base de reglas contiene dos reglas borrosas del tipo Takagi y Sugeno [37]:

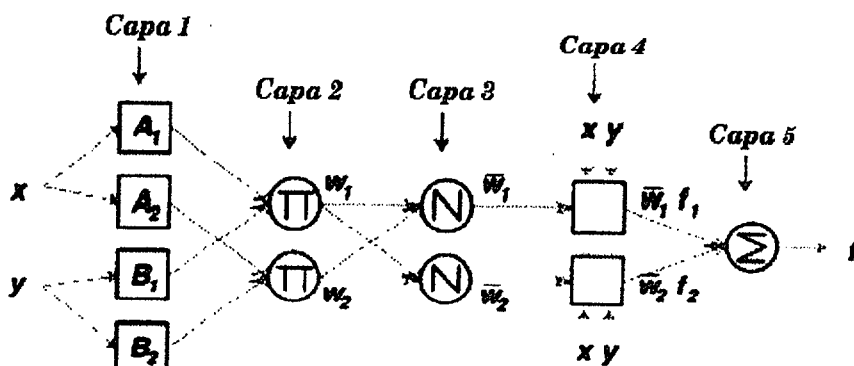
Regla 1: SI x_1 es A_1 Y x_2 es B_1 , ENTONCES $f_1 = p_1 \cdot x_1 + q_1 \cdot x_2 + r_1$

Regla 2: SI x_1 es A_2 Y x_2 es B_2 , ENTONCES $f_2 = p_2 \cdot x_1 + q_2 \cdot x_2 + r_2$

Este razonamiento borroso del tipo 3 se representa en la Figura 2.8(a) y la correspondiente arquitectura del ANFIS equivalente (ANFIS tipo 3) se muestra en la Figura 2.8(b). Las funciones nodales de la misma capa son de la misma familia de funciones [24], tal como se describe a continuación:



(a)



(b)

Figura 2.8.- (a) Modelo borroso de Sugeno de primer orden con dos entradas y dos reglas (tipo 3); (b) Arquitectura del ANFIS equivalente.

Capa 1: Todos los nodos i de esta capa son nodos cuadrados con la función nodal:

$$O_i^1 = \mu_{A_i}(x) \quad (2.5)$$

Donde “ x ” es la entrada al nodo i , y “ A_i ” es el nombre (o etiqueta) lingüístico (pequeño, grande, etc.) asociado a esta función nodal. En otras palabras, “ O_i^1 ” es la función de pertenencia de A_i y especifica el grado con el que la entrada x dada satisface el cuantificador A_i . Normalmente se elige $\mu_{A_i}(x)$ como una función con forma de campana (acampanada) con el máximo igual a 1 y el mínimo igual a 0, tal que:

$$\mu_{A_i}(x) = \frac{1}{1 + \left[\left(\frac{x - c_i}{a_i} \right)^2 \right] \cdot b_i} \quad (2.6)$$

o

$$\mu_{A_i}(x) = \exp \left\{ - \left(\frac{x - c_i}{a_i} \right)^2 \right\} \quad (2.7)$$

Donde $\{a_i, b_i, c_i\}$ es el conjunto de parámetros. Como los valores de estos parámetros cambian, las funciones acampanadas varían de acuerdo con estos cambios, mostrando así varias formas de funciones de pertenencia de la etiqueta lingüística A_i . De hecho, cualquier función continua y diferenciable a trozos, tales como las funciones de pertenencia con forma trapezoidal y triangular, también pueden utilizarse como funciones nodales de esta capa. Los parámetros de esta capa se denominan **parámetros premisa** o **parámetros antecedentes**.

Capa 2: Todos los nodos de esta capa son nodos circulares denominados “T” que multiplican las señales de entrada y envían el producto a la salida, es decir:

$$O_i^2 = w_i = \mu_{A_i}(x_1) \cdot \mu_{B_i}(x_2) \quad i = 1, 2. \quad (2.8)$$

Cada salida nodal representa el peso de una regla (de hecho, se pueden utilizar como funciones nodales de esta capa otros operadores T-norma que realizan el conector “y” generalizado).

Capa 3: Todos los nodos de esta capa son nodos circulares denominados “N”. El nodo i -ésimo calcula la relación del peso de la regla i -ésima con respecto a la suma de los pesos de todas las reglas:

$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2}; \quad i = 1, 2. \quad (2.9)$$

Por convenio, las salidas de esta capa se denominan **pesos normalizados**.

Capa 4: Todos los nodos de esta capa son nodos cuadrados con la función nodal:

$$O_i^4 = \bar{w}_i \cdot f_i = \bar{w}_i \cdot (p_i \cdot x_1 + q_i \cdot x_2 + r_i) \quad (2.10)$$

Donde \bar{w}_i son las salidas de la capa 3, y $\{p_i, q_i, r_i\}$ es el conjunto de parámetros. Los parámetros de esta capa se denominan **parámetros consecuentes**.

Capa 5: El único nodo de esta capa es un nodo circular denominado “ Σ ” que calcula la salida global como el sumatorio de todas las señales de entrada a esta capa, es decir:

$$O_i^5 = \text{Salida Global} = \sum_i \bar{w}_i \cdot f_i = \frac{\sum_i w_i \cdot f_i}{\sum_i w_i} \quad (2.11)$$

De esta forma, se ha construido una red adaptativa que funcionalmente es equivalente a un sistema de inferencia borroso del tipo 3 [26]. Para los sistemas de inferencia borrosos del tipo 1, la ampliación es bastante sencilla y el ANFIS del tipo 1 se muestra en la Figura 2., donde la salida de cada regla está provocada conjuntamente por la función de pertenencia de la salida y el peso. Para los sistemas de inferencia borrosos del tipo 2, si se sustituye el centroide como operador de defuzzificación por una versión discreta que calcule el centroide aproximado del área, entonces el ANFIS del tipo 2 puede construirse de la misma forma. Sin embargo, será más complicado que sus versiones tipo 3 y tipo 1 y por eso no vale la pena su realización.

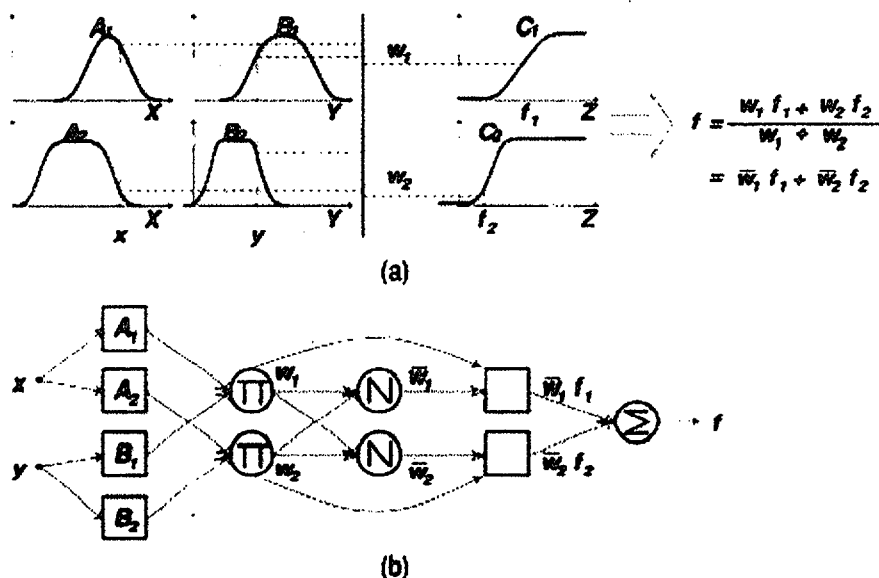


Figura 2.9.- (a) Modelo borroso de Tsukamoto con dos entradas (tipo 1); (b) Arquitectura del ANFIS equivalente.

La Figura 2.10 muestra un ANFIS del tipo 3 con dos entradas y nueve reglas. Hay tres funciones de pertenencia asociadas con cada entrada, así el espacio de las entradas está dividido en nueve subespacios borrosos, cada uno de los cuales está gobernado por una de

las reglas borrosas. El antecedente de una regla define un subespacio borroso, mientras que la consecuencia especifica la salida dentro de este subespacio borroso.

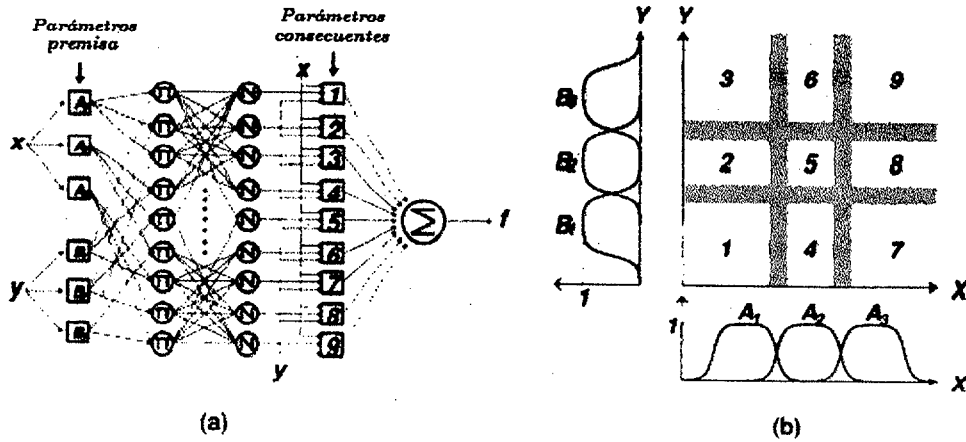


Figura 2.10.- (a) Arquitectura del ANFIS para un modelo borroso de Sugeno con dos entradas y nueve reglas (tipo 3); (b) Espacio de entrada dividido en nueve regiones borrosas.

2.7 ALGORITMO HÍBRIDO DE APRENDIZAJE

A partir de la arquitectura del ANFIS del tipo 3 que se propuso anteriormente se observa que dados los valores de los parámetros antecedentes, la salida global se puede expresar como una combinación lineal de los parámetros consecuentes. De forma más precisa, la salida f de la Figura 2.8 se puede escribir como:

$$\begin{aligned}
 f &= \frac{w_1}{w_1 + w_2} \cdot f_1 + \frac{w_2}{w_1 + w_2} \cdot f_2 \\
 &= \bar{w}_1 \cdot f_1 + \bar{w}_2 \cdot f_2 \\
 &= (\bar{w}_1 \cdot x_1) \cdot p_1 + (\bar{w}_1 \cdot x_2) \cdot q_1 + (\bar{w}_1) \cdot r_1 + (\bar{w}_2 \cdot x_1) \cdot p_2 + (\bar{w}_2 \cdot x_2) \cdot q_2 + (\bar{w}_2) \cdot r_2
 \end{aligned}
 \tag{2.12}$$

Que es lineal con respecto a los parámetros consecuentes (p_1, q_1, r_1, p_2, q_2 y r_2). Así pues:

$$S = S_1 \oplus S_2 \tag{2.13}$$

\underline{S} = conjunto de los parámetros totales

\underline{S}_1 = conjunto de los parámetros antecedentes.

\underline{S}_2 = conjunto de los parámetros consecuentes.

Donde $H(\cdot)$ y $F(\cdot, \cdot)$ son la función identidad y la función del sistema de inferencia borroso, respectivamente. Por lo tanto, se puede aplicar directamente el algoritmo híbrido de aprendizaje desarrollado anteriormente.

De una forma más específica, en el paso hacia delante del algoritmo híbrido de aprendizaje, las señales funcionales avanzan hasta la capa 4 y los parámetros consecuentes se identifican mediante la estimación por mínimos cuadrados. En el paso hacia atrás, las razones del error se propagan hacia atrás y los parámetros antecedentes se actualizan mediante el descenso del gradiente. La Tabla 2.2 resume las actividades realizadas en cada paso.

	Paso hacia adelante	Paso hacia atrás
Parámetros Premisa	Fijos	Descenso del gradiente
Parámetros consecuentes	Estimación mínimos cuadrados	Fijos
Señales	Salida de los nodos	Razón del error

Tabla 2.2.- Los dos pasos del procedimiento híbrido de aprendizaje para el ANFIS

Como se mencionó antes, los parámetros consecuentes identificados de esta forma, son óptimos (en el espacio de los parámetros consecuentes) con la condición de que los parámetros antecedentes sean fijos. Por consiguiente, la aproximación híbrida es más rápida que el descenso del gradiente estricto y es útil buscar las posibilidades de descomposición del conjunto de los parámetros. Para el ANFIS del tipo 1, esto se puede llevar a cabo si la función de pertenencia de la consecuencia de cada regla se reemplaza por una aproximación lineal a trozos con dos parámetros consecuentes (Figura 2.11). En este caso, de nuevo, los parámetros consecuentes constituyen el conjunto S_2 y se puede emplear la regla híbrida de aprendizaje directamente.




Figura 2.11.- Aproximación lineal a trozos de las funciones de pertenencia de las consecuencias en las reglas borrosas del ANFIS de Tsukamoto (tipo1).

Sin embargo, debería advertirse que la complejidad de cálculo de la estimación por mínimos cuadrados es mayor que la del descenso del gradiente [29]. De hecho, para actualizar los parámetros hay cuatro métodos que se enumeran a continuación de acuerdo con su complejidad de cálculo.

Descenso del gradiente: Todos los parámetros se actualizan mediante el descenso del gradiente.

Descenso del gradiente y un paso del LSE (estimación por mínimos cuadrados): La LSE se aplica sólo una vez al principio para obtener los valores iniciales y los parámetros consecuentes y a continuación el descenso del gradiente se encarga de la actualización de todos los parámetros.

Descenso del gradiente y LSE: éste es el propuesto en la regla híbrida de aprendizaje.

LSE secuencial (aproximación): El ANFIS se linealiza con respecto a los parámetros antecedentes y se emplea el algoritmo del filtro de Kalman para actualizar todos los parámetros.

La elección de los métodos mencionados se basa en el equilibrio entre la complejidad operacional y los resultados que se obtienen. Hay que observar que los parámetros consecuentes también pueden actualizarse mediante el algoritmo LMS de Widrow-Hoff [45]. El algoritmo de Widrow-Hoff requiere un menor cálculo y favorece la implementación paralela de hardware, pero converge relativamente lento cuando se lo compara con la estimación por mínimos cuadrados (LSE).

El mecanismo de aprendizaje no debería aplicarse a la determinación de las funciones de pertenencia ya que expresan las descripciones lingüísticas y subjetivas de conceptos vagos e imprecisos. Éstas dependen de lo que se piense en ese momento sobre estos conceptos y su elección debería dejarse en manos del operador. En principio, si el tamaño del conjunto de datos entrada/salida disponibles es bastante grande, entonces es aplicable (o necesario) un afinamiento o ajuste de las funciones de pertenencia ya que su determinación está sujeta a las diferencias de opinión de los expertos y las diferencias en el tiempo; por lo tanto, rara vez están optimizadas para obtener la salida deseada. Sin embargo, si el conjunto de datos es demasiado pequeño, es probable que el conjunto de datos no contenga suficiente información del sistema que se está considerando. En esta situación, las funciones de pertenencia determinadas por los operadores a través de sus experiencias representan una fuente importante de conocimiento que podría no estar reflejado en el conjunto de datos; por lo tanto, estas funciones de pertenencia deberían mantenerse fijas durante el proceso de aprendizaje.

Ya que las fórmulas actualizadas de los parámetros antecedentes y consecuentes se separan en la regla híbrida de aprendizaje, (ver Tabla 2.2.2), se puede aumentar la velocidad del aprendizaje utilizando otras versiones del método del gradiente en los parámetros antecedentes, tales como el descenso del gradiente conjugado, la propagación hacia atrás de segundo orden, la propagación rápida, la optimización no lineal y muchos otros.

2.8 ALGORITMOS DE AGRUPACIÓN DE LA INFORMACIÓN (‘CLUSTERING’)

Los **algoritmos de agrupación** (“*clustering*”) se utilizan extensamente no sólo para organizar y clasificar información, sino también para comprimir o reducir esta información y construir un modelo [7]. A continuación se presentan cuatro de las técnicas de agrupación “off-line” más representativas, utilizadas frecuentemente junto con redes de funciones radiales básicas (“*Radial Basis Function Networks*”) y con modelización borrosa [6]:

- **(Hard) C-Means (o K-means) Clustering** (C-Means Clustering).
- **Fuzzy C-Means Clustering** (C-Means Clustering Borroso).
- **The Mountain Clustering Method** (Método Mountain Clustering).
- **Subtractive Clustering** (Clustering Subtractivo).

El **Clustering** divide un conjunto de datos en varios grupos tal que la semejanza de estos datos dentro de un grupo es mayor que la de estos datos de diferentes grupos [5]. Llevar a cabo tal partición requiere una medida de la semejanza que, tomando dos vectores de entrada, devuelva un valor que refleje esta semejanza. Ya que la mayoría de las medidas de semejanza son sensibles a los rangos de los elementos de los vectores de entrada, cada una de las variables de entrada debe normalizarse dentro del intervalo unidad [0, 1]. Por eso, a partir de ahora se va a suponer que el conjunto de datos que se está considerando ya está normalizado dentro de un hipercubo unidad. Las técnicas de agrupación (“*Clustering*”) se utilizan junto con redes RBF o con modelización borrosa, principalmente para determinar la localización inicial de las funciones radiales básicas o de las reglas borrosas. Para lograr este propósito, las técnicas de agrupación serán válidas teniendo en cuenta las siguientes suposiciones:

- Las entradas similares al sistema del que se quiere obtener un modelo, deberían producir salidas similares.
- Estos pares de entrada/salida similares se colocan dentro de **agrupaciones** (“*clusters*”) en el conjunto de los datos de entrenamiento.

La primera suposición plantea que el sistema que se quiere modelizar, es una correspondencia uniforme de las entradas en las salidas; normalmente, esto es cierto para los sistemas reales. La segunda suposición requiere que el conjunto de datos se ajuste a algún tipo de distribución específica; sin embargo, esto no siempre es cierto. Por lo tanto, las técnicas de agrupación utilizadas para la identificación de estructuras en modelización neuronal o borrosa son altamente heurísticas, y no es extraño encontrar un conjunto de datos en el que las técnicas de agrupación no se puedan aplicar satisfactoriamente.

2.9 AGRUPACIÓN SUBTRACTIVA. ('SUBSTRUCTIVE CLUSTERING')

El método de Mountain Clustering descrito anteriormente es relativamente sencillo y efectivo. Sin embargo, su cálculo crece exponencialmente con la dimensión del problema ya que el método debe evaluar la función 'mountain' sobre todos los puntos del mallado. Por ejemplo, en un problema de agrupación con cuatro variables en el que cada dimensión tiene una resolución de 10 líneas de mallado, resultaría un mallado de 10^4 puntos que deberán ser evaluados. Una aproximación alternativa es el '*Subtractive Clustering*' propuesto por Chiu [10], en el que los datos (no los puntos del mallado) se consideran como posibles centros. Utilizando este método, el cálculo es sencillamente proporcional al número de datos e independiente de la dimensión del problema que se está considerando. Sea una colección de n datos $\{x_1, \dots, x_n\}$ en un espacio de M dimensiones. Sin perder generalidad, se supone que estos datos se han normalizado en un hipercubo. Ya que cada dato es un posible centro, la **medida de la densidad** de los datos x_i se define como:

$$D_i = \sum_{j=1}^n \exp \left(- \frac{\|x_i - x_j\|^2}{\left(\frac{r_a}{2}\right)^2} \right) \quad (2.14)$$

Donde " r_a " es una constante positiva. Por lo tanto, un dato tendrá un valor de densidad alto si tiene muchos datos vecinos. El radio " r_a " define la **vecindad**; los datos fuera de este radio contribuyen sólo un poco en la medida de la densidad.

Después de calcular esta medida de la densidad para cada dato, se elige como primer centro el punto que tenga la mayor densidad y es seleccionado como el primer centro. Sea " x_{c_1} " el punto seleccionado y " D_{c_1} " su densidad. A continuación, la densidad de cada punto x_i se revisa mediante la fórmula:

Donde “ r_a ” es una constante positiva. Por lo tanto, un dato tendrá un valor de densidad alto si tiene muchos datos vecinos. El radio “ r_a ” define la **vecindad**; los datos fuera de este radio contribuyen sólo un poco en la medida de la densidad.

Después de calcular esta medida de la densidad para cada dato, se elige como primer centro el punto que tenga la mayor densidad y es seleccionado como el primer centro. Sea “ x_{c_1} ” el punto seleccionado y “ D_{c_1} ” su densidad. A continuación, la densidad de cada punto x_i se revisa mediante la fórmula:

$$D_i = D_i - D_{c_1} \cdot \exp \left(- \frac{\|x_i - x_{c_1}\|^2}{\left(\frac{r_b}{2}\right)^2} \right) \quad (2.15)$$

Donde “ r_b ” es una constante positiva. Por lo tanto, los datos que están próximos al centro “ x_{c_1} ” tendrán densidades significativamente reducidas, haciendo que estos datos tengan muy pocas opciones de poder ser seleccionados como próximos centros. La constante “ r_b ” define la vecindad que tienen las reducciones medibles en la densidad, y normalmente es mayor que “ r_a ” para prevenir centros muy próximos: Generalmente r_b es igual a $1,5 \cdot r_a$.

Después de revisar la densidad de cada dato, se selecciona el próximo centro x_{c_2} y todas las densidades de los puntos se revisan de nuevo. Este proceso se repite hasta que se hayan generado un número de centros suficientes.

Cuando se aplica el Subtractive Clustering a un conjunto de datos de entrada/salida, cada uno de los centros representa un prototipo que muestra ciertas características del sistema que se modelizará. Estos centros se utilizan razonablemente como centros para las premisas de las reglas borrosas en un modelo borroso de Sugeno de orden cero, o para las funciones radiales básicas en una RBFN. Por ejemplo, se supone que el centro para la agrupación i -ésima es c_i en un espacio de M dimensiones. El c_i se puede descomponer en dos vectores componentes p_i y q_i , donde p_i es la componente de entrada y contiene los primeros N elementos de c_i ; y q_i es la componente de salida y contiene los restantes $M-N$ elementos de c_i . Así, dado un vector de entrada x , el grado con el que satisface la regla borrosa i se define como:

$$\mu_i = \exp \left(- \frac{\|x - p_i\|^2}{\left(\frac{r_a}{2}\right)^2} \right) \quad (2.16)$$

Esto también es la definición de la función radial básica i -ésima si se realiza el modelado utilizando las RBFN. Una vez que se ha determinado la premisa de una regla borrosa (o una función radial básica), la consecuencia (o pesos para la salida de una RBFN) se puede estimar mediante el método de los mínimos cuadrados. Después de completarse estos procedimientos, se puede conseguir una mayor precisión utilizando el algoritmo del descenso del gradiente u otros esquemas avanzados de optimización basados en la derivada para un mayor refinamiento.

CAPÍTULO 3

DATOS DE LOS SENSORES DEL HORNO ALTO SUS TRATAMIENTOS

3. INTRODUCCIÓN

A lo largo de los últimos veinte años se ha realizado un esfuerzo serio por parte de las industrias siderúrgicas para optimizar el control del Horno Alto [13]. Se ha profundizado enormemente en el conocimiento del proceso en sí mismo y se han probado una enorme variedad de modelos tanto globales como parciales. También se han mejorado los sistemas de carga, la calidad y preparación de las materias primas; se han diseñado dispositivos de medida cada vez mejores y se han implantado sistemas de control automático.

Hoy día es práctica habitual en los hornos modernos las técnicas de mejora del rendimiento del mismo tales como el aumento de la presión de trabajo del horno, la inyección de fuel o la inyección de carbón pulverizado. Por otro lado, la necesidad de conseguir altos niveles de producción de arrabio a bajo coste junto con la saturación del mercado mundial de acero ha llevado a la construcción de Hornos Altos cada vez mayores.

Los procesos que tienen lugar en el Horno Alto son difíciles de controlar por varias causas. Las principales son la fuerte no-linealidad de los mismos, los tiempos de retardo que pueden ser de horas e incluso de días, la dificultad para tomar medidas sobre los parámetros significativos, así como el ruido en la medida y las perturbaciones no controladas.

Esta tesis se ha centrado en el desarrollo de modelos basados en lógica borrosa – y en menor medida de redes neuronales- para conocer la evaluación de las tendencias futuras de la temperatura del arrabio. El objetivo de este estudio fue realizar un modelo predictivo de la temperatura del arrabio para ser utilizado junto con un sistema de aviso que proporcione al operador de planta una ayuda para mantener controlado en todo momento el horno alto.

Durante la investigación se han desarrollado y validado diferentes sistemas de lógica borrosa. A pesar de las diferencias entre las aproximaciones, se pueden identificar cuatro pasos, comunes en todas las actividades, y son los siguientes:

- **Adquisición y preparación de los datos.**
- **Preprocesamiento de los datos.**

- **Desarrollo del sistema de lógica borrosa.**
- **Evaluación de los resultados obtenidos.**

3.1 LOS DATOS: ADQUISICIÓN Y PREPARACIÓN

Una de las fases más críticas de las aproximaciones basadas en la lógica borrosa viene marcada por la necesidad de tener un conjunto de datos grande, significativo y libre de ruido. Se necesita una gran cantidad de datos para asegurar una amplia descripción de todas las posibles situaciones del proceso. Los datos tienen que ser significativos, pues deben representar los fenómenos principales que el modelo tiene que incluir para una descripción del proceso satisfactoria. Finalmente, los datos tienen que estar libres de ruido tanto como sea posible, para aumentar la eficacia del entrenamiento, y evitar la inclusión de información no significativa en el modelo que se va a desarrollar.

Desgraciadamente, todos estos requisitos no son fáciles de obtener de un proceso industrial, y en particular para el proceso del horno alto. No es posible dar una respuesta sobre la dimensión del conjunto de datos satisfactorio que tiene que utilizarse para el problema de la predicción de la temperatura del arrabio, sin embargo, se han obtenido algunas indicaciones generales gracias a la experiencia de los operadores de planta:

- La dimensión de los datos de entrenamiento tiene que estar relacionada con la realidad del horno.
- En el caso de un horno muy estable, tanto en las condiciones de operación del proceso como en el suministro de material bruto, es necesario utilizar un conjunto de entrenamiento grande.
- En el caso de situaciones de proceso más inestable, es decir, debido a la gran variación de las características del material bruto, es mejor utilizar un conjunto de datos más corto. De esta forma, es posible obtener una eficacia muy buena del modelo de lógica borrosa de forma local, pero con una disminución de la eficacia global en periodos largos (menor capacidad de generalización).

El segundo problema es la evaluación del significado del conjunto de datos. Las cuestiones que hay que resolver son las siguientes: ¿Se presentan todas las situaciones del proceso en el conjunto de datos? ¿Se encuentran presentes con la misma frecuencia en el conjunto de los datos? La respuesta a la segunda pregunta está vinculada a la primera. Desgraciadamente no es posible definir un método de validación general y aceptable para establecer si el conjunto de datos es –o no lo es– una imagen buena de la complejidad del proceso. En este caso se ha llevado a cabo una inspección manual de las tendencias de las variables del proceso basándose en el juicio de los expertos.

El tercer problema está representado por el ruido que está presente en los valores del conjunto de datos. Para clarificar algunas consideraciones futuras, es importante especificar algunas distinciones concernientes al significado del ruido [3], que se puede considerar como la suma de los diversos factores que afectan a la estimación de los valores de las variables del proceso. Estos son:

- **Errores de medida:** Son debidos a la mala medida de las variables. Esta forma de ruido puede ser realmente peligrosa cuando el rango de la variación de la medida es comparable con el rango de la acción de regulación típica.
- **Errores de muestreo:** Son debidos a la adquisición incorrecta al realizar una observación parcial de la variable medida.

Se pueden observar tres grupos de entrada que se denominan *Variables Manipuladas*, *Perturbaciones* y *Variaciones naturales*; y dos grupos de salida, denominadas *Variables medibles* y *Variables no medibles*. El significado de estas variables son los siguientes:

Entradas:

Variables manipuladas: Son las que usa el operador para regular el proceso. Todas estas variables son teóricamente conocidas y controlables. Normalmente son las variables de entrada por la tobera (unos ejemplos de estas variables son la humedad y la inyección de carbón).

Perturbaciones: Son variables de proceso que el operador no puede controlar. En general, se pueden considerar como variables con variaciones de frecuencia muy pequeñas. Normalmente, son las características físicas y químicas del material del horno y de la distribución de la carga (por ejemplo, la relación mineral/coque).

Variaciones naturales: Son variaciones, impredecibles e incontrolables, de las condiciones del proceso. En general, se pueden considerar como variables con frecuencias altas.

Salidas:

Variables medibles: son las que el operador puede medir. Todas estas variables son teóricamente conocidas y observables. Normalmente, son los gases de la parte superior y las características del arrabio y de la escoria.

Variables no medibles: son variables que el operador no puede medir. Normalmente, son las variables internas del proceso.

Estas variables también pueden clasificarse de otra forma, incluyéndolas en cuatro categorías:

Parámetros de la cuba: En esta categoría se han incluido dos variables: la relación mineral/coque que debe considerarse como una entrada, y la velocidad de descenso de la carga.

Entradas por las toberas: que incluyen las entradas clásicas al horno alto: temperatura, caudal, humedad y presión, todas ellas de la soplante.

Composición del gas de escape: Se han incluido en esta categoría el % de monóxido de carbono, el % de dióxido de carbono y el % de hidrógeno en los gases de escape, así como las trece medidas de las temperaturas de los gases recogidas a lo largo del tragante del horno alto mediante una sonda horizontal.

Propiedades del arrabio: Esta categoría incluye la temperatura del arrabio y los contenidos de silicio y azufre en el mismo.

Las siguientes figuras muestran la representación de las variables que se han utilizado para la realización del modelo durante un periodo aproximado de una semana de operación (cada unidad de muestreo representa 10 minutos). La selección de estas variables se ha realizado por los operadores de planta según la importancia de éstas en el proceso de control del horno alto. Las variables de entrada son la humedad, la inyección de carbón, el caudal, el oxígeno, la presión, la temperatura de la soplante y la relación mineral/coque; y la variable de salida es la temperatura del arrabio.




Figura 3.1.- Humedad de la soplante




Figura 3.2.- Inyección de carbón

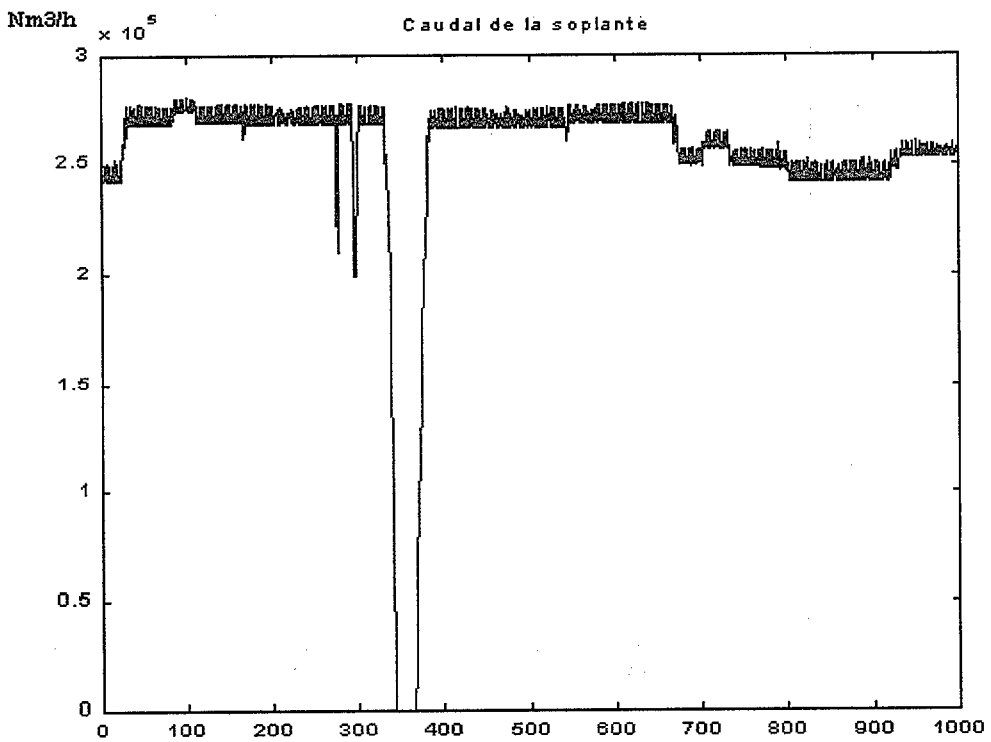


Figura 3.3.- Caudal de la soplantè




Figura 3.4.- Oxígeno de la soplante




Figura 3.5.- Temperatura de la soplante.




Figura 3.6.- Relación mineral/coque.




Figura 3.7.- Temperatura del arrabio.




Figura 3.8.- Presión de la soplante.

Estos datos provienen del Horno Alto B de Aceralia en Gijón. Se han proporcionado dos conjuntos con diez mil datos cada uno, lo que implica la información de aproximadamente cuatro meses y medio de operación de este horno alto. En general, la medición de todas las variables de operación es automática, excepto para las variables que son medidas cada vez que se realiza una colada, y se almacenan en el ordenador de proceso con un tiempo de muestreo de 10 minutos.

La medición real se realizó con un intervalo de muestreo de 2 segundos; pero, por motivos de espacio en disco, para facilitar su manejo y para poder realizar un estudio a largo plazo, se ha realizado una media de los valores hasta adoptar primero un periodo de muestreo de 10 segundos, posteriormente de 2 minutos y, por último, tras realizar el mismo procedimiento, obtener unos datos con un periodo de muestreo de 10 minutos (este proceso se ha realizado en la misma planta de Aceralia). Pero los datos proporcionados sobre el arrabio no tienen un tiempo de muestreo igual para todas las muestras: viene determinado por el proceso de colada del horno alto.

3.1.1 TEMPERATURA DEL ARRABIO: PREPARACIÓN

Durante la fase de preparación de los datos, se han obtenido dos conjuntos de datos con diferentes periodos de muestreo. En el primero, las variables tienen todas el mismo periodo de muestreo, que es de 10 minutos, como se ha señalado antes y que, por lo tanto, no necesita preparación de los datos. En el segundo, las variables (entre ellas está la temperatura del arrabio) tienen distinto periodo de muestreo que viene definido por los instantes en los que se realizan las coladas y que, por tanto, necesitan una preparación previa de éstos [27].

Como se ha dicho anteriormente, se han realizado normalmente tres mediciones de la temperatura del arrabio durante el periodo que dura la colada: la primera se realiza, normalmente, en los primeros instantes del inicio de la colada; la segunda se realiza más o menos a la mitad de la colada y la tercera en los momentos finales. La primera medición suele ser la más baja, ya que el arrabio que sale al principio por la piquera está más frío que el arrabio que sale al final de la colada. Esto puede ser debido a que mientras el horno esté cerrado, el arrabio situado cerca de la piquera, que es el primero en salir, pierde calor al cederlo a los refractarios que forman las paredes del crisol.

Normalmente, la última medición es la que tiene un valor más alto porque una vez que se ha vaciado el crisol, el arrabio que sigue descendiendo al crisol de las zonas superiores sale directamente por la piquera. Además, una vez que se ha realizado la medida, el valor se ha repetido hasta que se ha realizado la siguiente, obteniendo una representación gráfica falsa en forma de almena del valor real de la temperatura del arrabio (ver figura 3.6).

Por lo tanto, la medida que realmente puede representar el valor real de la temperatura del arrabio es la última medida que se realiza en cada colada. Debido a esto, y para simplificar el cálculo, se va a considerar sólo un valor de la temperatura del arrabio suponiendo que permanecerá constante durante toda la colada. De esta forma, ahora se tienen tantos datos como coladas se han realizado durante el periodo de tiempo en el que se han proporcionado los datos.

Para conseguir que la temperatura del arrabio tenga un número igual de muestras que el resto de variables, se ha realizado una interpolación mediante una 'spline' cúbica de los datos seleccionados (ver Figura 3.9). Además, con esta aproximación se suaviza la representación de la temperatura del arrabio ya que realmente, debido a las grandes inercias del horno alto, los cambios en las variables de entrada afectan de una forma suave a la temperatura del arrabio.




Figura 3.9.- Representación de unos 1.000 valores de la temperatura del arrabio reales (en azul) e interpolados (rojo).

3.2 REPROCESAMIENTO DE LOS DATOS

El ruido en los datos es uno de los elementos más importantes que afectan a la calidad de la predicción. La medida de la temperatura del arrabio es un problema muy complejo, que puede estar afectado por muchas perturbaciones diferentes [27]. Las principales están enumeradas aquí:

- La medida se realiza manualmente.
- El error de medida del termopar es significativo.
- Cambio del valor de la temperatura del arrabio durante la colada.

En general, el operador sigue unos procedimientos estandarizados para medir la temperatura, con el objetivo de reducir el rango del posible error de medida. A pesar de todo esto, el rango del error se puede estimar aproximadamente en ± 5 °C.

Un segundo aspecto importante es que el proceso puede mostrar rangos de fluctuaciones pequeños que aumentan la variación local de la temperatura del arrabio, pero que son extremadamente difíciles de describir por el modelo. Este tipo de información se debe, en general, a fenómenos a corto plazo que producen variaciones locales del proceso alrededor de condiciones estables del mismo. En general, estos no son importantes para el control de todo el proceso y se pueden no tener en cuenta. Estas fluctuaciones desconocidas son las que se van a tratar como ruido, y para eliminarlo se utilizarán los filtros [45].

3.2.1 FILTRADO DE DATOS

El tratamiento de señales es una rama de la ingeniería que trata fundamentalmente de la realización de filtros para eliminar o reducir componentes frecuenciales no deseadas de una señal portadora de información. Lo que se va a realizar es, en esencia, modificar las características de respuesta en frecuencia con un filtro de paso de banda. Para ilustrar la forma en que funciona un filtro de paso de banda, se va a pasar del dominio temporal al dominio frecuencial. Todas las realizaciones de filtros específicos para una cierta aplicación se pueden agrupar en cuatro tipos generales de filtros: **pasabaja**, **pasaalta**, **pasabanda** y **eliminador de banda** [19].




Figura 3.10.- Características de respuesta en frecuencia de los cuatro tipos básicos de filtros.

La respuesta en frecuencia característica de estos filtros se ha representado en la Figura 3.10. Los filtros adaptativos tienen unas características que son específicas para la aplicación a la que estén destinados. Pueden reproducir las características de cualquiera de los cuatro tipos básicos de filtros, independientemente o en combinación.

El efecto del filtro cambia la respuesta local de la señal pero no afecta a la respuesta a medio o largo plazo [46]. Esto significa que, desde el punto de vista operacional, la señal filtrada mantiene todo el contenido de información y por lo tanto, se puede considerar todavía como una buena descripción de la evolución de la temperatura del arrabio.

La elección de la frecuencia de corte está vinculada al límite impuesto por el teorema de muestreo de Shannon que define la relación entre la frecuencia de muestreo, f_s , y la componente de la frecuencia más alta de la señal, f_{\max} , es decir:

$$f_s \geq 2 \cdot f_{\max} \quad (3.1)$$

En términos de tiempo de muestreo:

$$T_{\max} \geq 2 \cdot T_s \quad (3.2)$$

La elección correcta de la frecuencia de corte tiene que cumplir dos requisitos opuestos: el primero de ellos es la disminución de la frecuencia de corte para reducir el ruido de la señal; el segundo es aumentar la frecuencia de corte para mantener la máxima cantidad de información que contiene la señal. Como una solución de compromiso de las consideraciones anteriores, se ha optado por utilizar un filtro pasabajos apropiado: se ha utilizado un filtro Butterworth, debido a su buena respuesta a frecuencias muy bajas. Tiene $2N-1$ derivadas nulas en $f = 0$ y $f = \infty$ y una respuesta global monótona, decreciendo suavemente de $f = 0$ a $f = \infty$ (N es el orden del filtro).

Un ejemplo claro de la necesidad de utilizar filtros es el caso del caudal de la soplante. Esta variable muestra más o menos una serie de picos (Figura 3.11) que se repiten sucesivamente y que tienen unas frecuencias muy altas (Figura 3.12). Estos picos son debidos a los cambios de estufas que se realizan, para poder mantener una temperatura del aire que entra por la soplante al horno y que se realiza aproximadamente cada media hora (3 periodos de muestreo).




Figura 3.11.- Representación de 100 datos del Caudal de la soplante.




Figura 3.12.- Espectro de frecuencias para los 100 datos del Caudal.

En la Figura 3.12 se representan 100 valores de esta variable filtrada al utilizar un filtro Butterworth pasabajos de cuarto orden y con una frecuencia de corte de $0,8 \cdot 10^{-3}$. Como se observa, los picos han desaparecido en la señal filtrada debido a que la frecuencia de estos es superior a la frecuencia de corte seleccionada (Figura 3.13a).




Figura 3.13.- Filtrado de la señal del caudal de la soplante donde la línea continua de color azul representa la señal antes del filtrado, y la línea roja después del filtrado

3.3 ANÁLISIS DE LOS DATOS

3.3.1 HISTOGRAMAS DE LAS VARIABLES

Un histograma consiste en un sistema cartesiano en cuyo eje de abscisas figuran los puntos indicativos de cada suceso o los intervalos entre los que se hallan comprendidos. En el eje de ordenadas figuran las frecuencias relativas, indicadas por barras, puntos, rectángulos o incluso por dibujos que aludan a la variable objeto de muestreo. El perfil delimitado por los extremos de esas figuras origina la curva de frecuencias. Por lo tanto, el histograma representa la distribución de los valores de cada una de las variables. A continuación se muestran los histogramas de las variables que se han utilizado en este proyecto, en los que es fácil identificar, en algunos casos, los valores consignados en los que el horno trabaja normalmente.




Figura 3.14.- Histograma de la humedad.




Figura 3.15.- Histograma de la inyección de carbón.




Figura 3.16.- Histograma del caudal.

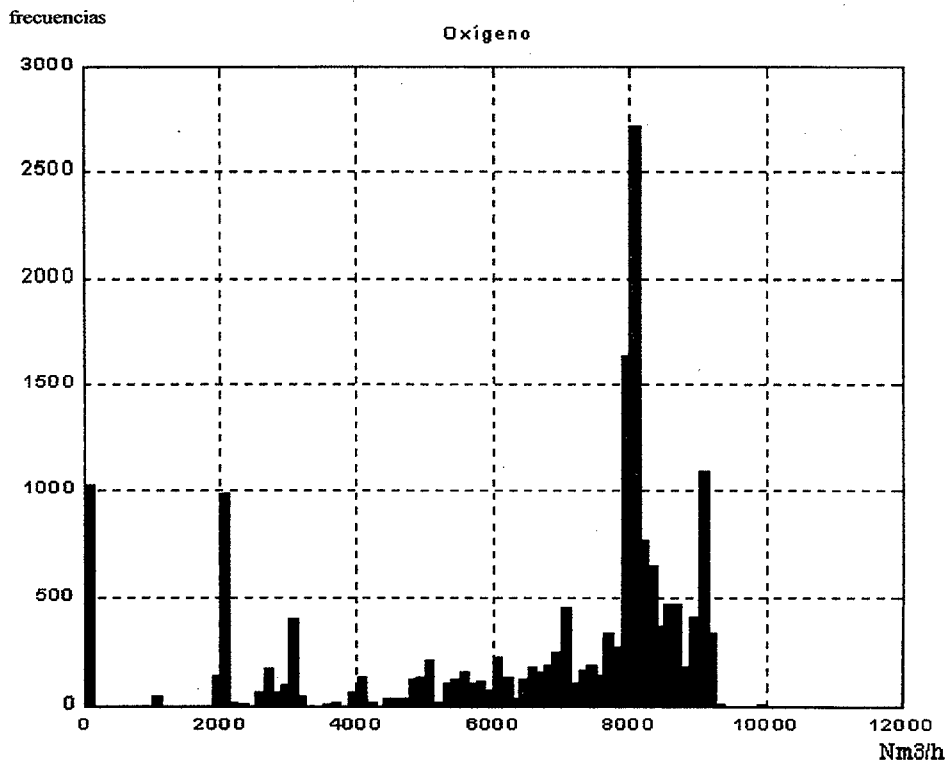


Figura 3.17.- Histograma del oxígeno.




Figura 3.18.- Histograma de la temperatura de la soplante.




Figura 3.19.- Histograma de la relación mineral/coque.




Figura 3.20.- Histograma de la temperatura del arrabio.




Figura 3.21.- Histograma de la presión.

En la Figura 3.14 se observa que no hay un valor que predomine sobre los demás, sino que hay varios que tienen una altura considerable. Esto induce a pensar que la humedad es una variable que se utiliza para intentar mantener la temperatura del arrabio en un valor establecido (en este caso en 1500 °C), es decir, es una variable de control. Lo mismo ocurre con la inyección de carbón (ver Figura 3.15) en el que se observa que hay un pico aproximadamente en 41 t/h pero alrededor de este valor también hay bastantes picos con valores considerables, por tanto, también es una variable de control.

En el caso del caudal (ver Figura 3.16) se observa un pico muy significativo sobre los 265.000 Nm³/h. Los demás picos están muy por debajo de su valor, siendo más una variable de consigna que de control, aunque de vez en cuando también se utiliza como refuerzo a las otras acciones de control. El oxígeno (ver Figura 3.7) es una variable muy influenciada por el caudal ya que es un % del valor de ésta; y en menor medida por la inyección de carbón. Por lo tanto, es una variable que no puede considerarse como una variable de control, como puede verse en los dos picos que están situados sobre los 8 000 Nm³/h. La temperatura de la soplante (Figura 3.18), muestra un comportamiento muy estable durante todo el proceso del horno obteniendo el pico máximo sobre los 1200 °C. Los demás picos son despreciables en cuanto a magnitud se refiere comparándolo con éste. Esto induce a pensar que esta variable es una variable de consigna.

Para la temperatura del arrabio (Figura 3.20), el perfil del histograma origina una curva de frecuencias que es bastante similar a una gaussiana centrada en 1485 °C. De esto se deduce que el operador de planta intenta mantener la temperatura en un valor de consigna (en este horno es de 1500 °C). El operador, cuando se percata que la temperatura va a sobrepasar este valor, introduce la acción de control adecuada para reducir la temperatura del arrabio y viceversa; de esta forma, se producen unas grandes oscilaciones alrededor del valor de consigna. Uno de los objetivos de esta tesis es intentar proporcionar un sistema de aviso que prediga con suficiente antelación estas oscilaciones para que el operador de planta tenga tiempo de corregirlas y reducirlas lo más posible, optimizando así, la calidad del arrabio obtenido.

3.3.2 ANÁLISIS DE LA CORRELACIÓN CRUZADA

Con el análisis de la correlación cruzada, es posible obtener los retrasos en el tiempo entre las variables que se están estudiando, y también la relación mutua entre ellas. Estos análisis podrían ser muy importantes para obtener resultados satisfactorios con el sistema de lógica borrosa. La función de la correlación cruzada entre dos conjuntos de datos se define por:

$$\hat{R}_{xy}(rh) = \frac{1}{N-r} \sum_{n=1}^{N-r} y_n \cdot x_{n+r} \quad (3.3)$$

Esta función se ha normalizado para obtener valores entre 1 y -1:

$$\hat{r}_{xy}(rh) = \frac{\hat{R}_{xy}(rh)}{\sqrt{\hat{R}_x(0)} \cdot \sqrt{\hat{R}_y(0)}} \quad (3.4)$$

La función de la correlación cruzada se ha obtenido entre las variables de entrada y la temperatura del arrabio para el periodo de -24 a 24 horas (287 periodos de muestreo) y los resultados se representan en las siguientes figuras.

- R_{XY} Relación de correlación cruzada estimada.
 r Número de retrasos.
 H Periodo de muestreo.
 X_i, Y_i Entrada normalizada.




Figura 3.22.- Correlación cruzada entre la humedad y la temperatura del arrabio.




Figura 3.23.- Correlación cruzada entre la inyección de carbón y la temperatura del arrabio.




Figura 3.24.- Correlación cruzada entre el caudal y la temperatura del arrabio




Figura 3.25.- Correlación cruzada entre el oxígeno y la temperatura del arrabio.




Figura 3.26.- Correlación cruzada entre la temperatura de la soplante y la temperatura del arrabio.




Figura 3.27.- Correlación cruzada entre la relación mineral/coque y la temperatura del arrabio.




Figura 3.28.- Autocorrelación de la temperatura del arrabio.




Figura 3.29.- Correlación cruzada entre la presión y la temperatura del arrabio.

3.3.2.1 CONCLUSIONES DEL ESTUDIO DE LAS CORRELACIONES

Los resultados obtenidos de este estudio no son lo bastante buenos para poder obtener alguna consecuencia lo suficientemente buena para poderla utilizar en el modelo basado en la lógica borrosa. Ninguna de las correlaciones obtenidas concuerda con los retrasos proporcionados por los operadores de planta. Según estos últimos, los retrasos que hay que aplicar a cada una de las variables son los que se expresan en la Tabla 3.1:

Variables	Retrasos (horas)
Humedad	2
Inyección de carbón	2
Caudal	2
Oxígeno	2
Presión	2
Temperatura del soplo	4
Relación mineral/coque	8

Tabla 3.1.-Retrasos de las variables de entrada.

Además algunas correlaciones dan como resultado un pico situado a la derecha del centro, es decir, se obtienen correlaciones positivas. Una explicación puede ser que en el sistema, al estar en ciclo cerrado, la situación del pico se puede deber a las acciones de control que realiza el operador para mantener la temperatura del arrabio sobre el valor de consigna.

3.3.3 ANÁLISIS DE COMPONENTES PRINCIPALES

El análisis de componentes principales es una técnica utilizada para estudiar las relaciones de la covarianza con un conjunto de datos mediante la investigación de un número de variables independientes dentro de sistemas lineales [16]. El objetivo es reducir la dimensionalidad del conjunto de datos, a un número menor de relaciones sin una pérdida significativa en la contribución a la variación del conjunto de datos. Todas las técnicas implican el estudio de la estructura dentro de una matriz de covarianza mediante la extracción de los valores y vectores propios de ésta. Estas similitudes se basan en el análisis de los valores propios de la matriz de covarianza.

Tiene tres funciones:

- Identificar las asociaciones naturales de las variables (que necesitan interpretarse).
- Reducir un gran número de variables de datos originales a un número pequeño de nuevas variables que consisten en las asociaciones naturales.
- Proporcionar una similitud en la composición de cada observación.

La suma de las diagonales de la matriz de valores propios proporciona la varianza total del conjunto de datos. Esta matriz también define un elipsoide de m dimensiones. Los vectores propios representan los ejes principales de este elipsoide y los valores propios la longitud de estos ejes. Estos vectores propios representan la varianza del conjunto de datos con la suma de los valores propios igual a la varianza total. Cada vector propio, justifica un valor de la varianza total igual al valor propio dividido por la traza. La dimensionalidad del conjunto de datos originales puede reducirse de m variables a p , que son los ejes principales que responden de una proporción significativa de la varianza total.

El análisis de componentes principales se ha realizado utilizando las entradas por la tobera y también la relación mineral/coque. Se han elegido estas variables porque van a utilizarse en la implementación del modelo de lógica borrosa. De esta forma, las variables que se han estudiado son:

- Caudal por la tobera (Q_v).
- Oxígeno (O_2).
- Presión (P_{sop}).
- Temperatura (T_{vc}).
- Relación mineral/coque (m/c).
- Inyección de carbón (In).
- Humedad (U_{vc}).

Para realizar este análisis, se han utilizado todos los datos, para conseguir una mejor relación entre las diferentes variables. Las medidas de las variables son completamente diferentes, ya que no están en la misma escala [28]. Si el análisis de componentes principales se realizase sin normalizar las variables, no se obtendrán resultados significativos porque la variable que tiene los valores más grandes, tendrá un gran valor de covarianza, ya que sus valores propios serán mayores que los otros.

Por lo tanto, esta variable tenderá a dominar las primeras componentes principales, mientras que el resto no tendrán importancia. Las variables se han normalizado de la siguiente forma:

$$X^* = \frac{X - m}{\sqrt{s}} \quad (3.5)$$

Donde “m” es la media de la variable X y “s” es la varianza de la misma variable.

En la Tabla 3.2 se pueden ver los resultados obtenidos en el análisis de los componentes principales. Se ha calculado la matriz de covarianza. Esta matriz debe ser simétrica, y también los elementos de la diagonal principal deben tener un valor de 1, porque las variables se han normalizado.

	M/c	In	Uvc	Qv	O ₂	Psop	Tvc
m/c	1,0000	0,2861	0,0036	-0,1323	0,3265	0,2413	0,2379
In	0,2861	1,0000	0,0765	-0,2606	0,8346	0,5117	0,6079
Uvc	-0,0036	0,0765	1,0000	0,1892	0,1738	0,1349	-0,2653
Qv	-0,1323	-0,2606	0,1892	1,0000	-0,2497	0,3228	0,4922
O ₂	0,3265	0,8346	0,1738	-0,2497	1,0000	0,5752	0,6081
Psop	0,2413	0,5117	0,1349	0,3228	0,5752	1,0000	0,3128
Tvc	0,2379	0,6079	0,2653	0,4922	0,6081	0,3128	1,0000

Tabla 3.2.- Matriz de Covarianza.

Una vez que se ha obtenido la matriz de covarianza, es posible calcular los vectores propios y los valores propios de ella. De esta forma, la matriz de covarianza se ha descompuesto en dos matrices que están relacionadas mediante la siguiente expresión:

$$\Sigma = A \Lambda A' \quad (3.6)$$

En donde A es la matriz de vectores propios y Λ son los valores propios.

En la (Tabla 3.3) es posible observar la matriz de vectores propios y también los valores propios obtenidos para cada variable.

	m/c	In	Uvc	Qv	O₂	Psop	Tvc
m/c	0,0226	-0,0744	0,0063	-0,9498	-0,1325	-0,0187	0,2718
In	0,5491	-0,2182	-0,5862	0,1617	0,0990	-0,0574	0,5177
Uvc	0,1190	-0,1241	0,3244	-0,0805	0,7739	-0,5096	0,0094
Qv	-0,1479	-0,5847	-0,0991	0,0556	-0,4339	-0,6268	-0,2057
O₂	-0,7833	0,0748	-0,2272	0,1064	0,1536	-0,1196	0,5292
Psop	0,2175	0,5740	0,3226	0,1273	-0,3828	-0,4786	0,3568
Tvc	0,0327	0,5045	0,6210	0,1860	-0,1237	0,3170	0,4565
Valores propios	0,1468	0,2163	0,3085	0,8432	0,9145	1,5738	2,9969

Tabla 3.3.- Matriz de valores y vectores propios

La suma de los valores propios representará la varianza total posible de los datos, así si el valor propio de una variable se divide por la varianza total se obtendrá el tanto por ciento de la varianza que cubre esa variable (x). Se muestra cada componente con su valor propio y el tanto por ciento de la varianza acumulada que cubre estas variables.

	Valores Propios	% Varianza acumulada
Tvc	2,9969	42,81
Psop	1,5738	65,29
O₂	0,9145	78,36
Qv	0,8432	90,40
Uvc	0,3085	94,81
In	0,2163	97,90
M/c	0,1468	100,00

Tabla 3.4.- Valores propios y % de la varianza acumulada de cada variable

3.3.3.1 CONCLUSIONES DEL ESTUDIO DE LAS COMPONENTES PRINCIPALES.

El objetivo principal que se persigue al realizar el análisis de componentes principales es intentar reducir un elevado número de variables de los datos originales a un número de nuevas variables más pequeño, que consisten en asociaciones naturales de las primeras. Si se utilizan las componentes principales, cada nueva variable será una combinación lineal de las diferentes variables (Caudal, Oxígeno, Temperatura, Presión,

Inyección de carbón, Relación mineral/coque y Humedad), que se han utilizado en el estudio de las componentes principales.

Otra forma de realizar esta reducción, es utilizar las variables antiguas que estén más representadas en las nuevas variables.

Se puede observar que la temperatura de la soplante, la presión, el oxígeno y el caudal utilizan el 90,40 % de la varianza total, así se podría reducir el espacio de entrada original de 7 variables a un nuevo espacio de entrada de 4 variables.

El mayor inconveniente de este método es que los datos proporcionados por Aceralia no son lineales, y el análisis de componentes principales estudia las relaciones lineales entre las variables.

Además, entre las variables que se despreciarían estarían las dos variables de control que se utilizan en el horno alto (la humedad y la inyección). Por lo tanto, esto complica aún más su aplicación.

CAPÍTULO 4

APLICACIONES DESARROLLADAS USANDO "LOGICA BORROSA Y REDES NEURONALES"

4. MODELO PARA LA PREDICCIÓN DE LA TEMPERATURA DEL ARRABIO

La principal razón para diseñar un sistema de lógica borrosa para la predicción de la temperatura del arrabio es que cualquier acción de control que se realice debe tener en cuenta la evolución de este parámetro. Es inútil, por ejemplo, tomar una acción de control para mejorar la producción de Horno Alto en términos de ahorro de consumo de coque, si esta acción conlleva la pérdida del valor óptimo de la temperatura del arrabio.

Para obtener un modelo basado en la lógica borrosa para la predicción de la temperatura del arrabio, hay algunas consideraciones importantes que deberían tenerse en cuenta, y son las siguientes:

- Durante el proceso, los operadores de planta suelen cambiar los valores de las entradas del Horno Alto para obtener las propiedades del arrabio deseadas. Estas variaciones deberían evaluarse para intentar obtener el mejor modelo de lógica borrosa.
- Es importante el periodo de tiempo que ha transcurrido desde que se ha realizado una variación de las variables de entrada, ya que su influencia en las propiedades del arrabio debería ser diferente. Por ejemplo, si se ha cambiado la humedad del soplo a un valor mayor ya que la temperatura del arrabio era alta, y en poco tiempo se va a realizar una colada en el Horno Alto, la influencia de esta variación no es muy importante en las propiedades del arrabio, mientras que si este cambio se ha realizado unas horas antes del inicio de la colada, su influencia en las propiedades del arrabio será mayor.
- Debe evaluarse el periodo de tiempo que realmente tiene influencia en las propiedades del arrabio.

Como ya se sabe, hay varios parámetros que pueden modificarse en un sistema de lógica borrosa, como son el número de variables, el número de funciones de pertenencia, el tipo de sistema borroso, etc. Por esta razón se ha elegido una estructura del sistema, para ser entrenada con los datos obtenidos de cada periodo de tiempo considerado. A continuación se va a explicar la estructura del sistema de lógica borrosa que se ha generado.

Las variables seleccionadas de entre todas las proporcionadas por Aceralia, con la ayuda de los operadores de planta, son la humedad, la inyección de carbón, el caudal, el oxígeno, la temperatura de la soplante y la relación mineral/coque, teniendo en cuenta la importancia que éstas tienen en el control del proceso del horno alto. La presión se ha desechado porque su comportamiento es más de una variable de salida que de una entrada, al venir determinada por los demás parámetros de las entradas por la soplante. Estas variables se han incorporado al modelo con un retraso que han determinado también los operadores del horno, y que están especificados en la tabla 3.1.

Además, se han añadido otras variables basadas en las anteriores pero con un retardo de uno y dos periodos de muestreo, resultando, por tanto, tres variables de entrada por cada una de las variables seleccionadas anteriormente. De esta forma, como el periodo de muestreo es de 10 minutos, se valora en definitiva a cada variable en un intervalo de 30 minutos; es decir, por ejemplo, para la humedad, la inyección de carbón, el caudal y el oxígeno se está suponiendo que después de realizar una variación en sus respectivos valores, la temperatura del arrabio tarda de 2 horas a 2:30 horas en asimilar el cambio y actuar en consecuencia.

También se van a añadir al 'regresor' (o vector de regresión) la temperatura del arrabio en retraso: se han realizado distintos ensayos buscando una predicción óptima de la temperatura del arrabio, que se consiguió para un retraso de 4 periodos de muestreo (40 minutos). Realizando el mismo procedimiento que con las variables anteriores, al final se obtiene un total de 21 variables de entrada y una salida (la temperatura del arrabio).

Si se define la temperatura del arrabio en función de las entradas al modelo se tiene el siguiente sistema (también denominado **regresor**):

$$\hat{y}(t+1) = f(y(t-\tau_k), y(t-\tau_k-1), y(t-\tau_k-2), \dots, u_i(t-\tau_k), u_i(t-\tau_k-1), u_i(t-\tau_k-2))$$

$$i = 1, \dots, 6; \quad k = 1, \dots, 7$$

(4.1)

donde:

$\hat{y}(t+1)$: valor de la predicción de la temperatura del arrabio.

$y()$: salida del proceso (medidas de la temperatura del arrabio).

$u_i()$: entradas del proceso.

τ_k : retrasos de cada una de las variables, teniendo en cuenta los retrasos comentados anteriormente.

Tanto las $y()$ como las $u_i()$ son las entradas al modelo de lógica borrosa elegido. Así la estructura del sistema es como el representado en la Figura 4.1..

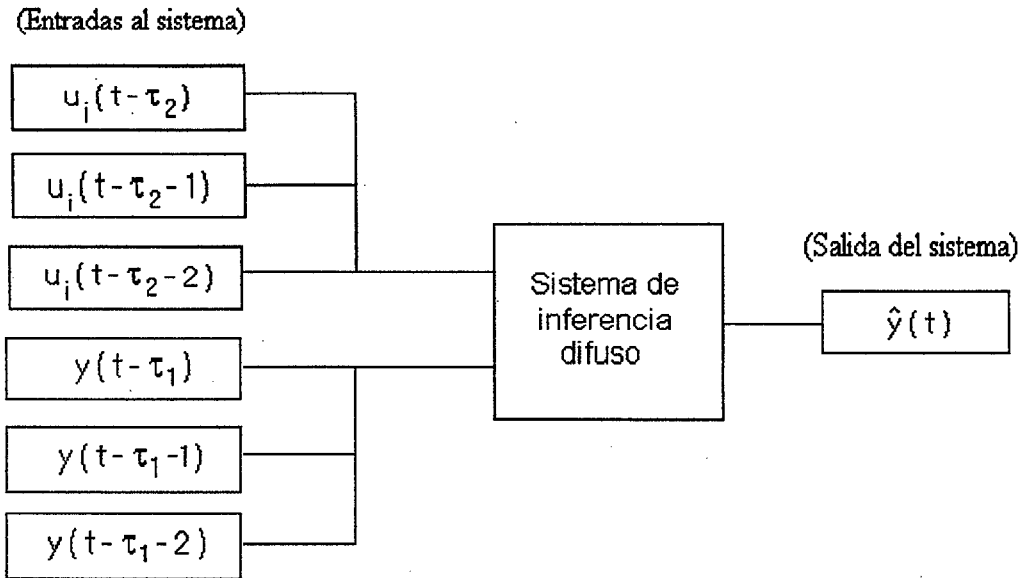


Figura 4.1.- Esquema del sistema borroso.

4.1 APLICACIÓN DE LOS ALGORITMOS DE ENTRENAMIENTO

De entre los distintos tipos de sistemas borrosos con los que se puede operar, se ha elegido el sistema de lógica borrosa de Takagi-Sugeno-Kang ya que permite entrenar el modelo mediante dos herramientas que están integradas dentro del paquete de software de lógica borrosa utilizado [7]: el **ANFIS** y el **Subtractive Clustering** (Agrupación Substractiva). Este sistema borroso utiliza las siguientes reglas Si-Entonces borrosas:

$$\text{SI } x_1 \text{ es } C_1^k \text{ y } \dots \text{ y } x_n \text{ es } C_n^k, \text{ ENTONCES } y^k = c_0^k + c_1^k \cdot x_1 + \dots + c_n^k \cdot x_n \quad (4.2.)$$

donde:

C_i^k : son conjuntos borrosos definidos en el sistema borroso.

c_i^k : son constantes.

x_i : son los valores que toman las entradas del modelo (" $y()$ " y " $u_i()$ " del regresor).

y^k : es el valor estimado de la temperatura del arrabio para la regla k .

$k = 1, 2, \dots, M$ ($M =$ número de reglas).

A la estructura del sistema borroso que se muestra en la Figura 4.1., se le han aplicado los dos algoritmos de entrenamiento siguientes:

1. Generación de una matriz de inferencia borrosa general y aplicación posterior del ANFIS (Sistema de Inferencia Neuro-Borroso Adaptativo) [21].
2. Aplicación del **Subtractive Clustering** (Agrupación Substractiva) [26].

4.1.1 APLICACIÓN DEL ANFIS

El ANFIS aplica dos técnicas para actualizar los parámetros: para los parámetros premisa, que definen las funciones de pertenencia, el ANFIS emplea el método del descenso del gradiente para ajustarlos; para los parámetros consecuentes, que definen los coeficientes de cada una de las ecuaciones de salida, el ANFIS utiliza el método de los mínimos cuadrados para identificarlos. Para lograr una buena generalización de la predicción, el tamaño del conjunto de datos de entrenamiento debería ser al menos tan grande como el número de parámetros modificables en el ANFIS [25]. En los sistemas de inferencia borrosos, hay tres tipos de particiones del espacio de entrada: partición por mallado, partición por árbol y partición por dispersión. En el ANFIS se utiliza la partición por mallado, y genera reglas mediante la enumeración de todas las combinaciones posibles de las funciones de pertenencia de todas las entradas, al no existir ningún tipo de entrenamiento previo. Esto lleva a un crecimiento exponencial en el número de reglas cuando el número de entradas es moderadamente grande. Por ejemplo, para el sistema de inferencia borroso que se está estudiando tiene 21 entradas y cada una de las cuales tiene 5 funciones de pertenencia; por lo tanto, de la partición por mallado se obtienen $5^{21}=4,77 \cdot 10^{14}$ reglas, que es inviablemente grande para cualquier método de aprendizaje práctico. Al final del entrenamiento se obtienen los c_i^k de las reglas (4.2).

4.1.2 APLICACIÓN DEL 'SUBSTRUCTIVE CLUSTERING'

Al aplicar el Subtractive Clustering, lo que se está realizando es estimar los centros de las agrupaciones de un conjunto de datos. Este método afirma que cada punto de información es un centro de agrupación potencial y se calcula un valor del potencial para cada punto de información basado en la densidad de puntos circundantes. El algoritmo selecciona el punto con mayor potencial como el primer centro de agrupación y entonces elimina el potencial de los puntos próximos al primer centro. Luego el algoritmo selecciona el punto con información con el mayor potencial de los que quedan como el próximo centro y elimina el potencial de los puntos próximos a este nuevo centro. Este proceso de adquisición de un nuevo centro y eliminación del potencial de los puntos circundantes se repite hasta que el potencial de todos los puntos caiga por debajo de un límite umbral. Los datos que pertenecen a una de estas agrupaciones (*clusters*) formadas, tienen algunas propiedades que los distinguen de los datos de otras agrupaciones. Primero

se agrupan los pares de datos entrada/salida dentro de agrupaciones de acuerdo con la distribución de los puntos de entrada, y se usa una regla borrosa para cada uno de las agrupaciones. La generación de la matriz del sistema de inferencia borroso se realiza mediante un entrenamiento inicial, anterior a su construcción, buscando relaciones entre las entradas y las salidas a priori y formando agrupaciones de datos que tienen un comportamiento similar, reduciendo, por tanto, el número de reglas borrosas (4.2) al número de agrupaciones encontradas. Así en la matriz de inferencia borrosa, cada una de las variables de entrada tendrá tantas funciones de pertenencia como agrupaciones se hayan encontrado y por tanto, también se creará el mismo número de reglas borrosas.

Un factor muy importante es el **radio de influencia**, (en este proyecto es de 0,3) que es un parámetro del algoritmo de entrenamiento, cuyo valor se determina mediante prueba y error: cuanto menor es el radio de influencia, se obtiene un mayor número de agrupaciones y, por tanto, se crean un mayor número de reglas y de funciones de pertenencia asociadas a cada una de las variables de entrada, consiguiendo un sistema más complejo y más preciso. Al final del entrenamiento se obtiene un número de reglas y los c_i^k de éstas (4.2).

4.2 RESULTADOS OBTENIDOS

El entrenamiento, tanto para el ANFIS como para el Subtractive Clustering, se ha realizado con 12.000 datos, mientras que la validación se ha realizado, para ambos, con 5.000 datos. En el caso del ANFIS se han obtenido unos resultados aceptables. Pero con el Subtractive Clustering, los resultados han sido muy buenos estando en muchos tramos por debajo del rango de error para la temperatura del arrabio que se estimó en aproximadamente ± 5 °C. La Figura 4.2 muestra la representación de 1.000 datos de la predicción de la temperatura del arrabio, realizada con el 'Subtractive Clustering', utilizando el conjunto de datos de entrenamiento. La Figura 4.3 muestra una ampliación de una parte de la Figura 4.2 para poder observar con más detalle los resultados.




Figura 4.2.- Predicción de la temperatura del arrabio con el conjunto de entrenamiento que se han representado 1 000 datos.

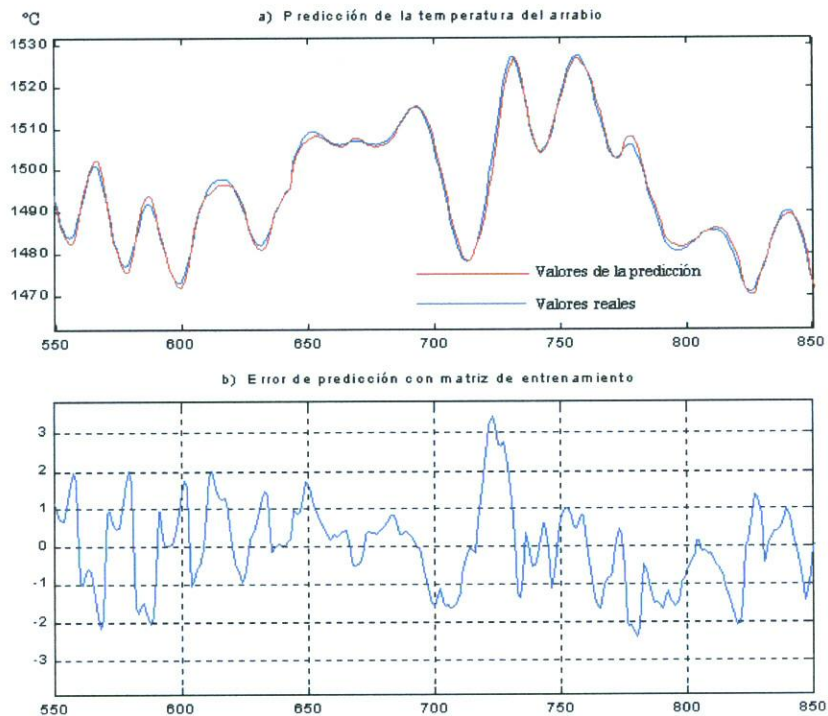


Figura 4.3.- Predicción de la temperatura del arrabio con el conjunto de entrenamiento que se han representado 300 datos.

La Figura 4.4(a) muestra la representación de 1.800 datos de la predicción de la temperatura del arrabio, realizada con el ‘Subtractive Clustering’, utilizando el conjunto de datos de validación.




Figura 4.4.- Predicción de la temperatura del arrabio con el conjunto de validación que se han representado 1 800 datos.

Como se puede observar tanto en la Figura 4.3(a) como en la Figura 4.4(a), la predicción no está retrasada con respecto a la medida real de la temperatura del arrabio, donde la línea continua azul representa a los valores medidos de la temperatura del arrabio y la línea continua roja representa la predicción de ésta. Tanto en la (a) como en la Figura 4.4(a) se observan con mayor precisión estas características. La Figura 4.4(b) y la Figura 4.5(b) muestran el error entre la medida real y la predicción de la temperatura del arrabio del entrenamiento y de la validación respectivamente. Se observa que este error es menor en el periodo de entrenamiento que en el de validación siendo, además, inferior a cinco grados en la mayor parte de los datos, que es el margen de error que tiene el termopar con el que se ha realizado la medida de la temperatura del arrabio.




Figura 4.5.- Predicción de la temperatura del arrabio con el conjunto de validación que se han representado 400 datos.

4.3 MODELO DE SIMULACIÓN

Utilizando herramientas de software, se ha diseñado un sistema que simula la temperatura del arrabio en un horno alto. De esta forma será posible simular cómo va a trabajar el sistema cuando se implante en el horno alto. El esquema de dicho sistema implementado es el que se muestra en la Figura 4.6.

Utilizando el modelo de simulación es posible observar la evolución de la temperatura del arrabio, de tal forma que en todo momento será posible que el operador de planta conozca cuál es la evolución hipotética de la temperatura citada; así si ésta va disminuyendo o aumentando, podrá predecirse y es posible determinar cuáles son las acciones de control principales que deberían realizarse para obtener la temperatura del arrabio deseada.

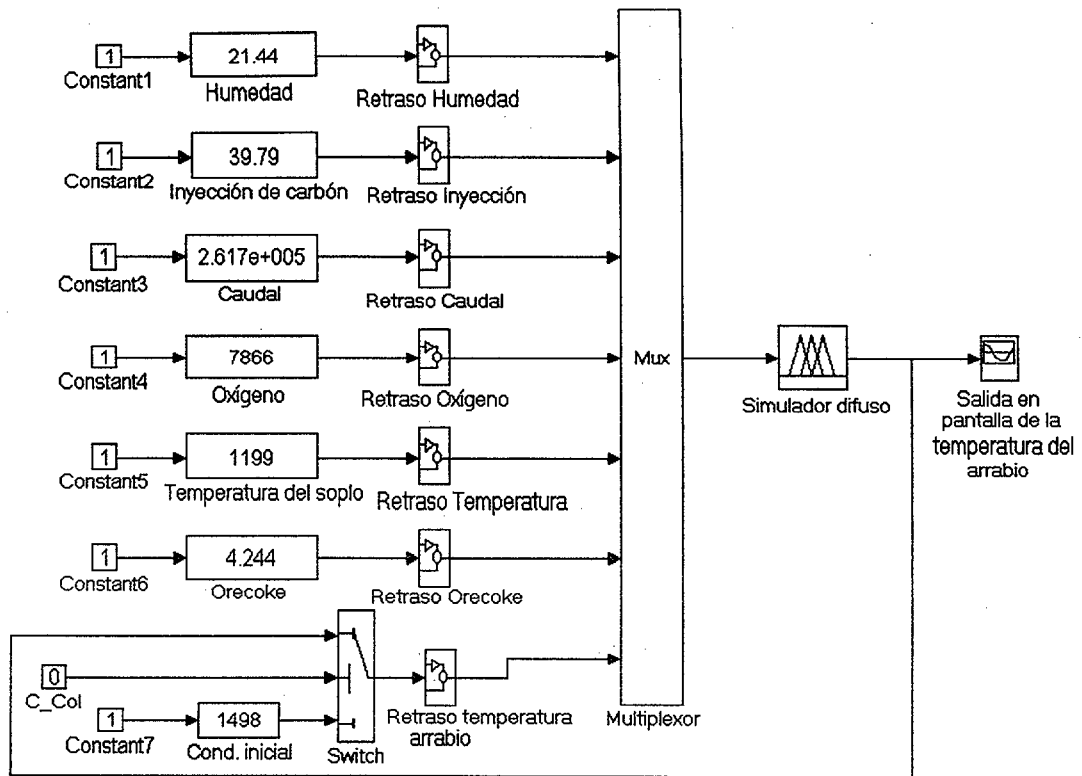


Figura 4.6.- Esquema del simulador borroso.

4.3.1 EVALUACIÓN DE LAS ESTRATEGIAS DE AVISO AL OPERADOR

Una vez que se ha realizado el modelo de simulación basado en lógica borrosa, es posible evaluar las diferentes estrategias de control que podrían desarrollarse para obtener la temperatura del arrabio deseada, minimizando el empleo de combustible y coque, y por supuesto, maximizando la productividad.

En la planta real, se utilizan la humedad y la inyección de carbón para controlar el horno alto y obtener las propiedades del arrabio buscadas, pero en muchas ocasiones estas acciones de control no se han realizado considerando que debe minimizarse el empleo de combustible y coque. Es obvio que si la temperatura del arrabio es muy alta, se ha consumido más combustible y coque, pero cuando la temperatura del arrabio es muy fría, las propiedades del arrabio podrían no ser lo bastante buenas. En los datos reales obtenidos de la planta, se descubre, en muchas ocasiones, que la variación de la temperatura del arrabio es muy alta de una colada a la próxima. Así el objetivo de este estudio es determinar cuáles son las mejores variaciones de la entrada que deberían realizarse para reducir el consumo de combustible y coque. Se han estudiado los efectos que producen las diferentes variaciones de la humedad, mientras el resto de las variables permanecen constantes. Se ha seleccionado un periodo de tiempo en donde se van a mantener constantes todas las entradas del simulador. Este criterio es importante porque si hay

algunas variaciones en las otras variables de entrada distintas a la que se va a variar, se podrían producir algunos efectos en la temperatura del arrabio que no son los esperados.

El procedimiento que se ha utilizado es la introducción de escalones de diferentes valores durante un periodo de tiempo. El periodo de tiempo se ha mantenido constante porque si el periodo de tiempo es muy corto, los efectos en las variables de salida serán diferentes que si el periodo de tiempo es más largo. Lo primero de todo, se ha introducido un valor de la humedad durante un periodo de tiempo y que se ha obtenido la respuesta del modelo. Después de obtener esta respuesta, se han introducido diferentes escalones en los datos de la humedad, para poder observar el comportamiento de la temperatura del arrabio en cada caso. Una vez que se han obtenido todas las respuestas (Figura 4.7) es posible determinar cuáles son los efectos de cada variación.




Figura 4.7.- Respuesta de la temperatura del arrabio a los cambios en la humedad.

Se ha realizado este mismo ensayo para la inyección de carbón (Figura 4.8) y el caudal (Figura 4.9). En todas las figuras puede observarse que el comportamiento de la temperatura del arrabio es el esperado para cada una de las variables modificadas.




Figura 4.8.- Respuesta de la temperatura del arrabio a los cambios en la inyección de carbón.




Figura 4.9.- Respuesta de la temperatura del arrabio a los cambios en el caudal.

4.3.2 RESULTADOS OBTENIDOS

Como es bien sabido (por la experiencia del operador de planta), si la humedad está en un valor alto, la temperatura del arrabio tiende a disminuir, y cuando la humedad tiene un valor bajo, la temperatura del arrabio tiende a aumentar.

En la Figura 4.7 es posible observar este efecto, y por lo tanto, si el escalón es positivo, la temperatura del arrabio será menor, así el horno alto se va enfriando; mientras que si el escalón es negativo, la temperatura del arrabio será mayor, y el horno alto se va calentando. Una vez que se ha obtenido en el horno alto el efecto de la variación de la humedad es interesante analizar si es posible mejorar la producción del horno alto. De esta forma, se han dado los siguientes pasos:

- Observando los datos en el periodo de tiempo mencionado antes, es posible determinar que para un valor de la humedad de 20 g/cm³ la temperatura del arrabio está un poco alta.
- De esta forma, la acción de control deseada es introducir un escalón positivo del 10 % del valor medio de la humedad, en el instante de tiempo de 1 000 periodos de muestreo, como se puede observar en la Figura 4.7 para obtener un valor de la temperatura del arrabio de 1500 °C.

De esta manera, el operador será capaz de determinar cuál es el periodo de tiempo y el valor de la humedad que se tiene que introducir para obtener la temperatura del arrabio deseada.

El efecto que produce la variación en el resto de las variables de entrada es similar al de la humedad, para obtener las estrategias de aviso para el operador, para minimizar el consumo de coque y combustible y maximizar la productividad.

4.4 CONCLUSIONES SOBRE LA APLICACIÓN DEL ANFIS

La principal característica del método utilizado es que, es posible determinar cuál va a ser la temperatura del arrabio en la próxima colada, dependiendo del tiempo que ha transcurrido desde la última colada que se ha realizado y dependiendo también del periodo de tiempo que la entrada se ha aplicado a un nivel (por ejemplo, humedad, inyección, etc.). Así, el operador de planta podrá conocer cuál va a ser la evolución del horno alto en cualquier instante de tiempo, dependiendo de las entradas del sistema.

Analizando cuidadosamente la temperatura del arrabio, se ha determinado que el factor principal para predecirla es determinar si el horno alto se está calentado o enfriando. De esta forma, el sistema de lógica borrosa obtenido es capaz de predecir estos cambios, y cuando la temperatura del arrabio disminuye debido a las modificaciones de las entradas

del horno alto, el sistema de lógica borrosa es capaz de predecir que la temperatura del arrabio va a ser más fría que la última.

Además de la característica del sistema borroso explicada anteriormente para la predicción de la temperatura del arrabio, el sistema de lógica borrosa es capaz de predecir el valor exacto de la temperatura del arrabio en muchas o bcasiones. Se ha determinado que el 93 % de los valores obtenidos con el sistema borroso tienen un error menor o igual al 3 % del valor real. Por lo tanto, se ha conseguido un sistema muy útil para el operador del horno alto ya que con el puede conseguirse mantener la temperatura del arrabio en su valor óptimo disminuyendo las oscilaciones alrededor de este valor.

4.5 APLICACIÓN REALIZADA USANDO REDES NEURONALES. ¿POR QUÉ EMPLEAR R.N.?

Las técnicas que usan Redes Neuronales (RN) se han empleado en el control y modelado en la industria siderurgia. Los modelos convencionales (físicos o termodinámicos) tienen unos inconvenientes que teóricamente los superan aquellos que han sido desarrollados con Redes Neuronales. La ventajas de los modelos que usan RN comparados con los que emplean los modelos convencionales son los siguientes:

- ❖ La posibilidad de encontrar relaciones complejas y no - lineales entre las variables, sin realizar los estudios estadísticos.
- ❖ Necesitan menos consumo de tiempo para el cálculo.
- ❖ Es también más fácil actualizar modelos basados en RN.
- ❖ Trasladar las actualizaciones a la planta en la que operan los modelos basados en RN es bastante más fácil.

No obstante no se pueden olvidar los inconvenientes:

- La estructura de las R.Ns. es semejante a " caja - negra"
- La habilidad para extrapolar modelos basados en RN es pobre.

Considerando todos los puntos antes descritos, se procede a seleccionar el tipo y estructura de la RN a usar.

4.5.1 CRITERIO DE SELECCIÓN DE LA R.N. PARA ESTA APLICACIÓN

Para desarrollar el modelo, se ha usado la teoría de identificación de sistemas. Se utilizó una colección de datos históricos –tanto de entrada como de salida – del Horno Alto intentando predecir la salida bajo estudio.

Es posible considerar el Horno Alto con la siguiente estructura:

$$y(t) = g(\varphi(t)) \quad (4.7)$$

$$\varphi(t) = [y(t-1), \dots, y(t-n), u(t-1), \dots, u(t-n)] \quad (4.8)$$

Donde:

$\hat{y}(t)$: es la predicción de salida

$\varphi(t)$: es el vector de la regresión.

$y(t)$: es el modelo de la salida .

$u(t)$: es el modelo de la entrada .

El vector de la regresión es una colección de datos de entrada y salida históricas del sistema, por ello es muy importante seleccionar este vector correctamente para obtener los resultados factibles. Es posible usar las Redes Neuronales para estimar las relaciones entre las variables. La red neuronal usada en la identificación del sistema es el típico perceptrón multicapa (MLP). En figura 4.9 se muestra un esquema de un perceptrón.

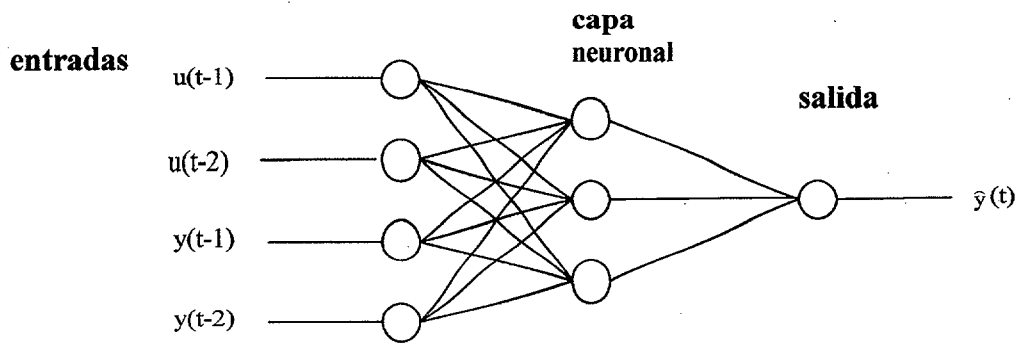


Figura 4.10. – Perceptrón multicapa.

Otra opción para obtener 'el regresor' es la red Función Base Radial (RBF). Se llevaron a cabo algunas pruebas con los algoritmos de entrenamiento disponibles para RBF, los resultados no fueron tan buenos como los conseguidos con el MLP. Así pues se seleccionó el MLP para desarrollar al modelo.

4.5.2 ESTRUCTURA DE LA RED NEURONAL PARA MLP

El MLP usado tiene tres capas, y se le entrenó con un caso particular del algoritmo de propagación hacia atrás: el método Levenberg - Marquardt. Este método es más rápido que el de propagación hacia atrás, sin embargo requiere gran cantidad de memoria. La expresión de este algoritmo es la siguiente:

$$\Delta W(k+1) = -\eta \left(\frac{1}{N} \sum_{t=1}^N \frac{\partial \hat{y}(t)}{\partial W(k)} \left(\frac{\partial \hat{y}(t)}{\partial W(k)} \right)^T + \delta I \right)^{-1} \frac{\partial J}{\partial W(k)} \quad (4.9)$$

donde:

$\Delta W(k+1)$: peso de adaptación al paso k.

η : razón de aprendizaje.

N: es el número de muestras.

$\hat{y}(t)$: La predicción de la salida.

I: La matriz de identidad.

J: $(J = \frac{1}{N} \sum_{t=1}^N (\hat{y}(t) - y(t))^2)$ (la función objetiva entrenando)

La primera capa es la de entrada cuyo número de neuronas es determinado por el número de componentes del vector de regresión. La segunda capa es la capa oculta cuyo número de neuronas es variable, y finalmente hay una neurona para la capa de la salida. Las funciones de transferencia usadas en las capas fueron respectivamente:.

- Función de transferencia Sigmoide en la capa oculta.
- Función de transferencia lineal en la capa de la salida.

El número de neuronas ocultas se seleccionó teniendo en cuenta el criterio de equilibrio: Un número pequeño de neuronas no puede encontrar relaciones entre las variables, y un número grande de ellas no permite generalizar los resultados obtenidos por la red.

4.6 DIVERSAS PREDICCIONES USANDO R.N.S.

4.6.1 PREDICCIÓN DE LA COMPOSICIÓN DE LOS GASES DE DESCARGA

Se crearon modelos basados en Rs.Ns., intentando predecir las magnitudes: % CO, % Co₂ y % H₂. Se usaron, para los modelos antes citados, la herramienta Red Neuronal de Identificación de Sistema. El regresor usado en todos los modelos fue el siguiente:

$$\hat{y}(t) = \varphi(y(t-10), y(t-20), y(t-30), u_1(t-10)) \quad (4.10)$$

donde:

$\hat{y}(t)$: La predicción de la salida.

$\varphi(t)$: el vector de la regresión

$y(t)$: El modelo de la salida.

$u(t)$: El modelo de la entrada.

En las figuras (4.11), (4.12), y (4.13) se representan los resultados obtenidos con esta aproximación. Las redes se entrenaron con 2.000 datos, y se validaron con 1.000 datos.




Figura 4.11 – Predicción y error de %CO.




Figura 4.12. – Predicción y error de %CO₂.

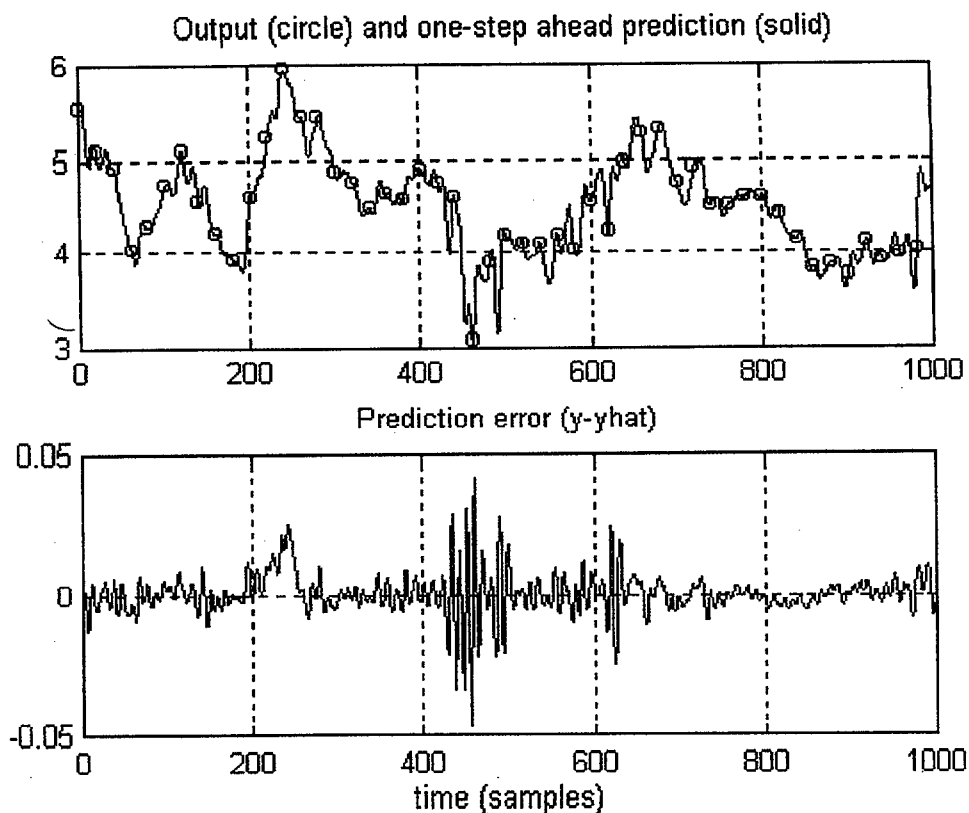


Figura 4.13. – Predicción y error de %H₂.




Figure 4.14. – Predicción de %CO con una aproximación autoregresiva-

En estos casos, se usaron, como entradas del modelo, la humedad y PCI. Cambiar estas entradas por otras no disminuyeron el error, por ello se testaron algunos regresores autorregresivos. La red se entrenó con 2.000 datos, y se validó con otros 1.000 datos. Se tomaron para el regresor cuatro salidas anteriores pero los resultados (representados en la figura 4.14 fueron bastante similares a los anteriores.

$$\hat{y}(t) = \varphi(y(t-10), y(t-20), y(t-30), y(t-40)) \quad (4.11)$$

donde:

$\hat{y}(t)$: Es la predicción de la salida.

$\varphi(t)$: Es el vector de la regresión.

$y(t)$: Es el modelo de la salida

4.6.2 PREDICCIÓN DE LA TEMPERATURA DEL ARRABIO.

Se desarrolló una red neuronal para predecir la temperatura del arrabio. Su estructura fue la de un perceptron multicapa clásico, entrenado usando el algoritmo Levenberg -Marquardt. El regresor usado fue el siguiente:

$$\begin{aligned} \hat{y}(t) = f(y(t-4), \dots, y(t-18), u_1(t-1), \dots, u_1(t-8), \\ u_i(t), \dots, u_i(t-8), u_8(t), \dots, u_8(t-11)) \\ i = 2, \dots, 7 \end{aligned} \quad (4.12)$$

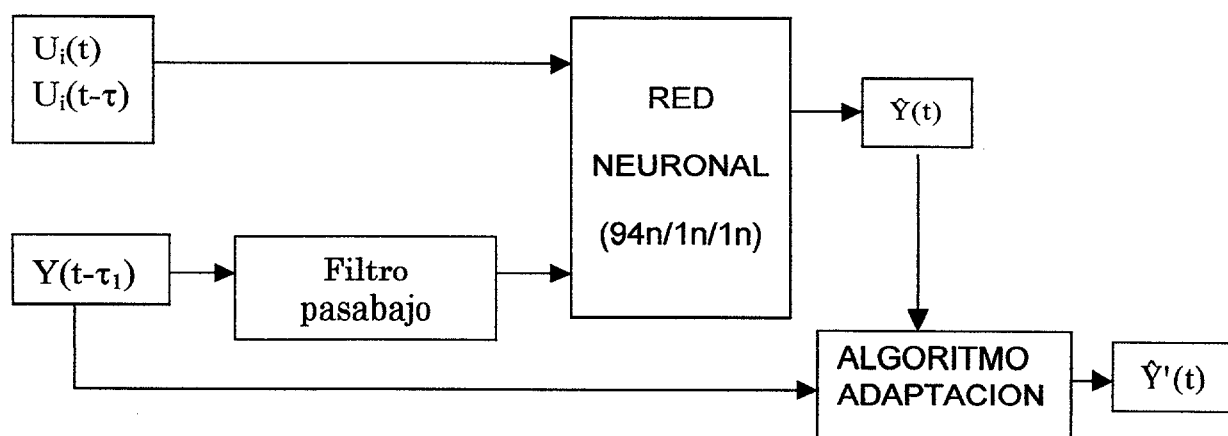


Figura 4.15. – Estructura de red neuronal.

En la tabla 4.1 se muestran las variables de entrada usadas en el modelo

ENTRADAS	SALIDAS (\hat{y})
Temp.arrabio	Predicción temp.arrabio.
Cargas/h.	
Soplado	
Presión Horno	
Temp. Horno.	
Humedad	
Oxígeno.	
Inyec.carbón pulv	
Presión superior.	

Tabla 4.1. – Entradas y Salidas del modelo de predicción temp. arrabio.

Uno de los resultados obtenidos se representa en figura 4.16




Figura 4.16. – Salidas Errores y predicciones de la red.

Se usó también otra red para predecir la temperatura del arrabio. Se entrenó con 4.000 datos, y se validó con 1.000 datos. El regresor usado fue el siguiente:

$$\hat{y}(t) = f(y(t - \tau_i), \bar{u}_i(t), \tau_i) \tag{4.13}$$

$$\bar{u}_i = \frac{\sum_{t=t_a-2\tau}^{t_a} e^{-2\left(\frac{[\tau-(t_a-t)]}{\tau}\right)^2} \cdot u_i(t)}{\sum_{t=t_a-2\tau}^{t_a} e^{-2\left(\frac{[\tau-(t_a-t)]}{\tau}\right)^2}} \tag{4.14}$$

donde:

τ_i = Tiempo transcurrido desde la medida previa.

τ = el retraso estimado para las variables de la entrada (depende de la variable)

τ_i = tiempos transcurridos descritos previamente.

En la tabla 4.2. se detallan las variables de entrada usadas en el modelo.

τ_i	OUTPUT (\hat{y})
Time Between taps	HMT prediction
Time since the tap beginning	
Time since the last measurement	
INPUTS (U_i)	
Blast Volume	
Blast Temperature	
Moisture	
Oxygen	
PCI	
Ore/Coke rate	
HMT delayed	

Tabla 4.2 – Variables de entrada a la Red Neuronal.

La estructura de la red neuronal se muestra en la figura 4.15

Algunos de los resultados obtenidos se representan en las figuras (4.16) y (4.17)




Figura 4.17. – Estructura de la red neuronal para predecir la temperatura del arrabio.





Figura 4.18. – Salida y diferentes predicciones de la red autopredicativa





Figure 4.19. – Salidas y diferentes predicciones de la red.

4.7 LA SIMULACIÓN DEL PROCESO CON REDES NEURONALES.

Una vez obtenido una Red capaz de validar el sistema, se implantó un simulador usando la herramienta Matlab Simulink para buscar el comportamiento del sistema. La red neuronal reproduce la temperatura del arrabio.

Un esquema del simulador se representa en figura 4.20.

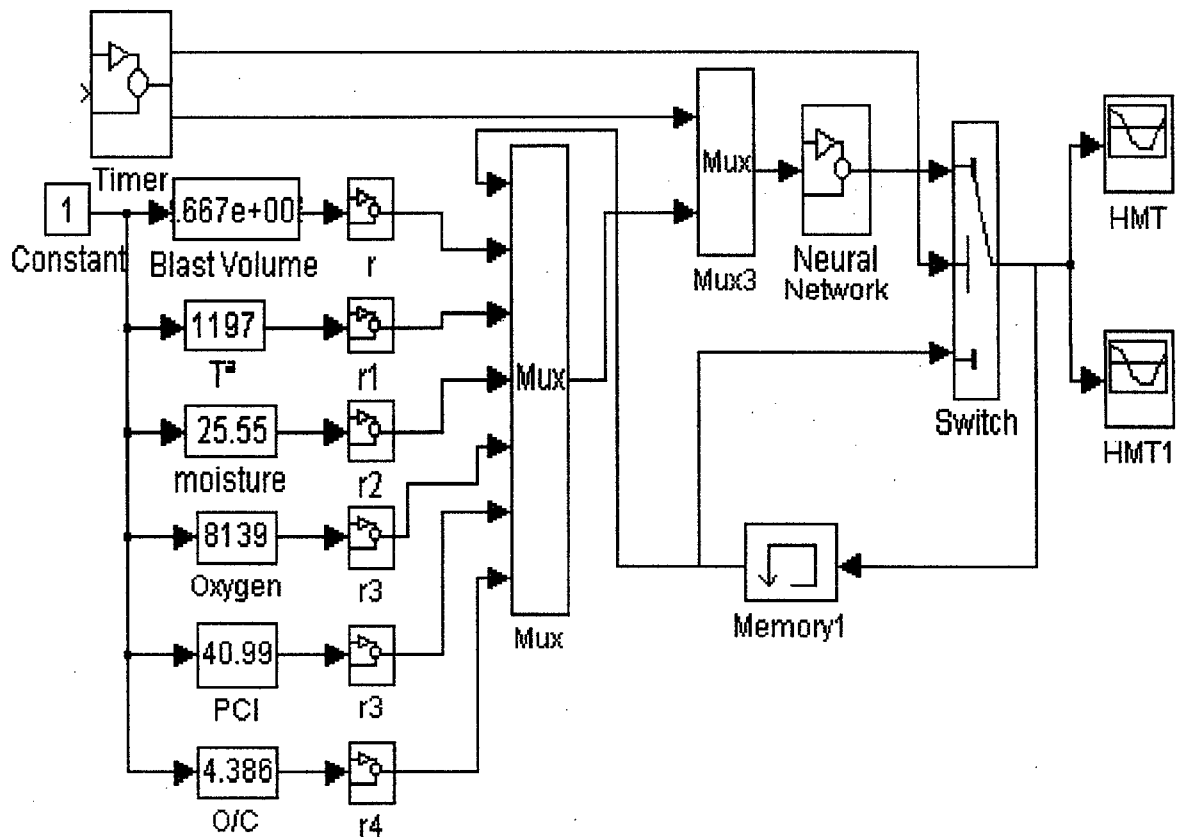


Figura 4.20. – Esquema del simulador con R.N.

Este simulador proporciona una guía a los operadores de la planta para aconsejarles sobre la tendencia de la temperatura del arrabio. Se pueden modificar las variables de la entrada para ver el cambio de la temperatura del arrabio. El simulador, basado en redes

neuronales, muestra la tendencia de la temperatura del arrabio para cambios en las entradas. Los resultados aparecen en la figura 4.21.

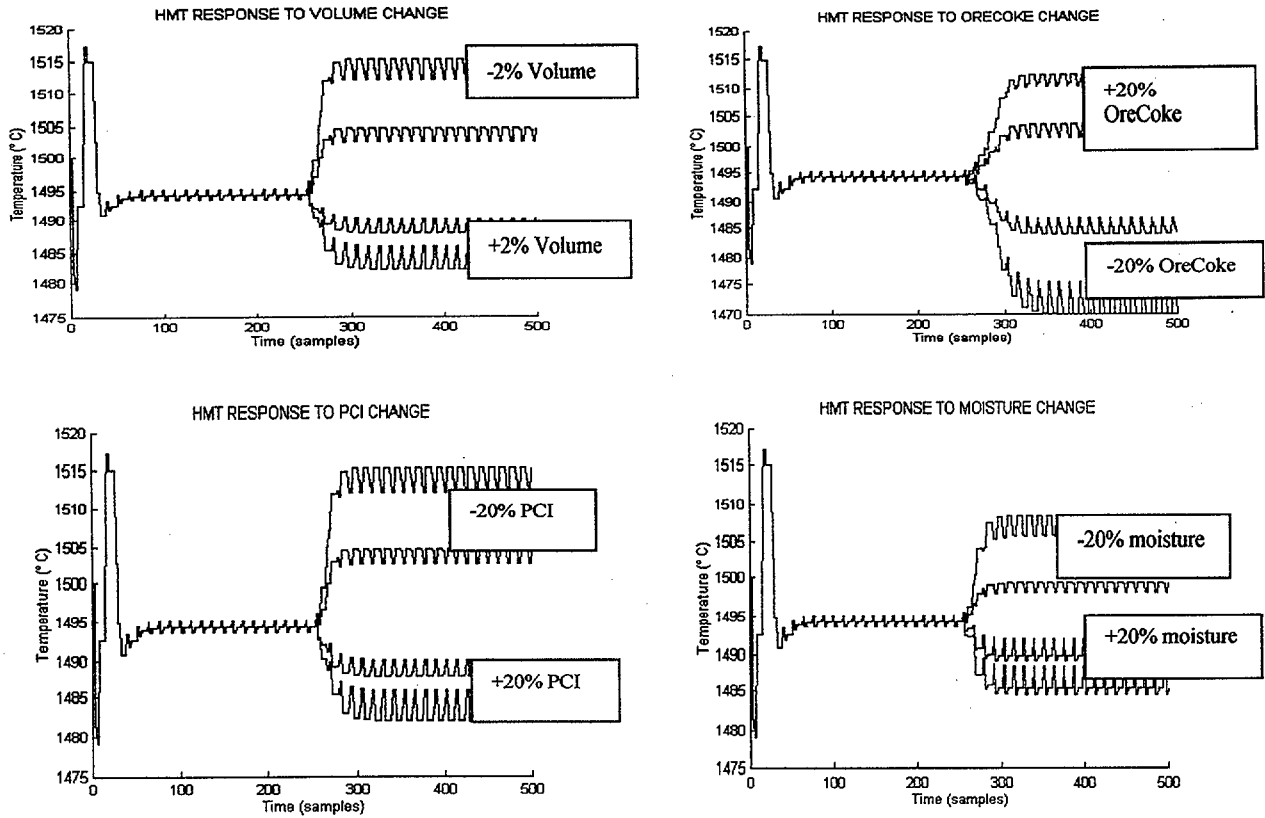


Figure 4.21. -NN Simulator responses.

CAPÍTULO 5

CONCLUSIONES

La presente tesis ha dado la oportunidad de probar un conjunto de diferentes técnicas de Inteligencia Artificial, que han producido resultados muy novedosos.

Los objetivos originales de la tesis fueron no sólo la solución de problemas de control específicos en el área de la fundición de hierro, sino que un objetivo más importante y general fue la evaluación de los posibles beneficios obtenidos por la aplicación de técnicas matemáticas nuevas y prometedoras para el apoyo y mejora del proceso de control.

Desde este punto de vista, la tesis demuestra la importancia de considerar esas técnicas como técnicas clave que, de hecho, no pueden ser ignoradas si se desea alcanzar una significativa mejora del control. Al mismo tiempo, esas técnicas no son la “panacea” para cualquier problema, de modo que una aplicación a ciegas de las mismas puede llevar a una pérdida de tiempo y a resultados pobres.

La ausencia de una potente formulación matemática es el problema real en la aplicación de las técnicas de inteligencia artificial. En la actualidad, no hay “teoremas” capaces de indicar y apoyar al investigador durante el desarrollo de sistemas basados en redes neuronales. Este problema destaca el papel del investigador y su habilidad en el manejo y aplicación de esos instrumentos matemáticos.

Finalmente, es interesante el resultado del desarrollo de controladores dinámicos del proceso en el Horno Alto que, en nuestra opinión es, uno de los objetivos más atractivos y prometedores.

La experiencia presente debe ser considerada sólo como exploradora, pero los alentadores resultados abren el camino a interesantes futuros estudios para una aplicación industrial real de control dinámico en bucles cerrados en Horno Alto, según se detalla a continuación. También se han presentado las diversas mediciones realizadas en el horno alto y los modelos aplicados para valorar el estado del proceso. Se han identificado aquellas técnicas que pueden ser consideradas ahora como bien establecidas y asentadas, comparadas con otras que todavía deben ser probadas y mejoradas.

FUTURO

Se señalan a continuación los huecos que se deben rellenar y se sugieren prioridades para el trabajo futuro:

PARTE ALTA DEL HORNO, POR ENCIMA DE LA CARGA

La composición y temperatura del gas en la parte superior se han convertido en mediciones de rutina que no presentan problemas destacables y que dan información importante sobre el proceso. Las mediciones de la distribución de la composición y temperatura del gas radial por medio de sondas por encima de la carga se utilizan ampliamente. Sin embargo, sus resultados son mas bien tendenciosos, tanto más cuanto mayor es la distancia a la superficie de la carga. La utilización de sondas inclinadas reduce los errores, pero se considera que las sondas internas a las cargas dan a menudo resultados mucho más representativos

Las mediciones del perfil de la carga por radar o sensores de microondas se realizan en una cantidad limitada de hornos; combinadas con modelos de llenado de carga permiten un buen control sobre la distribución de la carga.

La monitorización de la velocidad de descenso de la carga mediante sondas de nivel se puede realizar en prácticamente todos los hornos, aunque esas sondas dan solo información parcial sobre el descenso de la carga que afectan de uno a cinco puntos seleccionados. A partir de las lecturas de esas sondas, se pueden computar velocidades de descenso de la carga locales, aunque los resultados de esos cálculos no son completamente fiables. Las mediciones más completas de la velocidad de descenso de la carga a lo largo del perímetro del horno no han alcanzado todavía el estatus de una medición industrial fiable.

Otras áreas de futuras investigaciones son:

- Mediciones y control del flujo transversal de gas, así como su impacto sobre el funcionamiento del horno y eliminación de álcalis;
- Medición exacta de la distribución radial de la cantidad y análisis del polvo rechazado hacia la parte alta del horno;
- Velocidad local del gas;
- Evaluación del análisis del tamaño de la carga;
- Heterogeneidad circunferencial del flujo de material (sólidos y gases);

- Mediciones in situ del espesor de la capa de carga en la pared.

MEDICIONES EN LA PARED, CUBA Y ETALAJES.

Las mediciones de la presión de gas a lo largo del horno se están convirtiendo en mediciones de rutina en muchos otros hornos, del mismo modo que las mediciones de la temperatura en la pared del horno y elementos enfriadores. La distribución de la carga y de las pérdidas de calor se evalúan de acuerdo con dichas mediciones.

Las sondas internas de carga fijas dan generalmente una mejor imagen de las reacciones del horno que las sondas situadas por encima de la carga, exceptuando las sondas inclinadas. Para investigaciones especiales se utilizan sondas verticales (flexibles o sólidas) u horizontales sólidas, que descienden con la carga; sin embargo, debido a los elevados costes de operación implicados, su aplicación es muy limitada. Lo mismo sirve para los muestreos de polvo a lo largo de la pared del horno.

La aplicación de redes neuronales para la evaluación de los patrones de distribución de calor por la pared se está poniendo a prueba en la actualidad; son necesarios más trabajos destinados al desarrollo de una herramienta fiable para la detección precoz de la formación de acreciones.

Otras áreas que requieren investigaciones son:

- Flujo transversal de gas en cámara/cuba del horno;
- Sondeos con muestreo de materiales y gases en el cuba inferior para una mejor evaluación de las propiedades del material (comparándolo con los resultados de tests de laboratorio);
- Detección de acreciones y evaluación de su grosor;
- Evaluación del tamaño y forma de la zona cohesiva.

ZONA DE TOBERAS Y 'RACEWAY'

Las condiciones hostiles en esta zona del horno dificultan las mediciones y a duras penas puede realizarse cualquier medida de forma rutinaria, a pesar de la valiosa información que podría obtenerse. Sin embargo, se han hecho importantes esfuerzos en el pasado para medir características importantes como propiedades de materiales (en particular la degradación del coque) en esta zona del horno y la distribución de la temperatura radial y análisis del gas a lo largo del diámetro del horno. Varios hornos han

sido dotados de sondas muy caras para el muestreo de sólidos, líquidos y gases, mientras que en otros se han usado sondas móviles montadas en carritos desplazables. Se han conseguido mediciones del tiempo de residencia del gas o de la permeabilidad del hombre muerto mediante inoculación de helio en el horno o por inyección de helio a través de sondas horizontales en la tobera. Se han realizado mediciones esporádicas de la profundidad del 'raceway', distribución de temperaturas y la evolución de la composición del gas.

Sin embargo, todavía deben hacerse importantes esfuerzos para aclarar los siguientes puntos:

- La permeabilidad del hombre muerto;
- La frecuencia de renovación de los materiales en el hombre muerto;
- La variación en la forma y posición del hombre muerto.;
- El grado de combustión del carbón y otros combustibles auxiliares en el 'raceway';
- La profundidad del 'raceway' durante el funcionamiento del horno;
- La presión del gas a lo largo del radio del horno;
- El movimiento de material en el 'raceway'.

CRISOL DEL HORNO Y NAVE DE COLADA

Las mediciones de las temperaturas en la pared del crisol y base del horno y su explotación combinada con modelos matemáticos para la evaluación del perfil de desgaste del crisol se está convirtiendo en un trabajo de rutina; también se ha aplicado la resonancia acústica. La medición continua de la temperatura del metal caliente por medio de pirómetros de radiación se está extendiendo también, mientras que la medida del nivel líquido en el crisol, generalmente por técnicas EMF ("electro motive forces"), está todavía en fase de prueba, aunque ya se ha instalado en varios hornos. En diversas ocasiones se han realizado medidas de la permeabilidad del crisol.

No obstante, el crisol del horno es todavía una zona en la que se conocen mal muchos fenómenos. En particular están:

- las medidas de nivel por EMF; incluso aunque no se conozcan bien los fundamentos de esta medida;
- medidas continuas de la temperatura del metal caliente;

- medidas del grosor de la pared por medio de técnicas de resonancia acústica;
- vaciamiento de la carga del crisol;
- flujo de metal en el crisol;
- formación de acreciones en el crisol;
- volumen de las escorias

MODELOS

- ❖ análisis de los componentes principales;
- ❖ modelos de transferencia de calor; en el crisol
- ❖ modelos de flujo de metal en el crisol;
- ❖ redes neuronales artificiales para visualización de los procesos;
- ❖ modelo de control de las estufas del horno

BIBLIOGRAFÍA

- [1] Zadeh, L. A.; "Fuzzy Sets"; *Informat. Control*, 8, pp. 338-353; 1965.
- [2] Zadeh, L. A.; "Outline of a New Approach to the Analysis of Complex Systems and Decision Processes"; *IEEE Trans. On Systems, Man, and Cybern.*; SMC-3, n° 1, pp.28-44, 1971.
- [3] Mamdani, E. H.; "Applications of Fuzzy Algorithms for Simple Dynamic Plant"; *Proc. IEEE*, 121, n° 12, pp. 1585-1588, 1974.
- [4] Sugeno, M. y Nishida, M.; "Fuzzy Control of Model Car"; *Fuzzy Sets and Systems*, 16, pp. 103-113, 1985.
- [5] Mendel, Jerry M.; "Fuzzy Logic Systems for Engineering: A Tutorial"; The Math Works Inc. 1995
- [6] Zadeh, L. A.; "Fuzzy Logic"; *Computer*, vol 1, n° 4, pp. 83-93, 1988.
- [7] Yager, R. y Zadeh, Lotfi A.; "An Introduction to Fuzzy Logic Applications in Intelligent Systems"; Kluwer Academic Publishers, 1992.
- [8] Jamshidi, Mohammad; Titli, André; Zadeh, Lotfi A. y Bovene, Serge; "Applications of Fuzzy Logic. Towards High Machine Intelligence Quotient Systems"; Prentice-Hall, 1997.
- [9] Sugeno, M.; "Industrial Applications of Fuzzy Control"; Elsevier Science Pub. Co., 1985
- [10] Dubois, D. y Prade, H.; "Fuzzy Sets and Systems: Theory and Applications"; Academic Press, Nueva York, 1980
- [11] Trillas, E.; "Conjuntos Borrosos"; Editorial Vicens-Vives, Barcelona.
- [12] Jang, J.-S. R.; Sun, C.-T. y Mizutani, E.; "Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence"; Editorial Prentice-Hall, Inc. 1997
- [13] Zadeh, L. A.; "The Concept of a Linguistic Variable and its Applications to Approximate Reasoning: Parts I"; *Information Sciences*, vol 8, pp. 199-249; "Part II", *Information Sciences*, vol. 8, pp. 301-357; "Part III", *Information Sciences*, vol. 9, pp. 43-80; 1975.
- [14] Yan, J.; Ryan, M. y Power, J.; "Using Fuzzy Logic"; Prentice-Hall International, 1994.
- [15] Garrido, Manuel; "Lógica Simbólica"; Editorial Tecnos, S. A. 2ª edición 1991.
- [16] Zadeh, L. A.; "Toward a Theory of fuzzy Systems" *Aspects of Network and System Theory*, eds R. E. Kalman and N. DeClaris, New York: Rinehart and Winston, 1971.
- [17] Mamdani E. H. y Assilian, S.; "An Experiment in Linguistic Synthesis with a Fuzzy Logic Controller" *Int. J. Man. Mach. Studies*, 7, n° 1, pp. 1-13, 1975.
- [18] Pedrycz, W.; "An Identification Algorithm in Fuzzy Relational Systems"; *Fuzzy Sets and Systems*, 13, pp. 153-167, 1984.

- [19] Zadeh, L. A.; "A Theory of Approximating Reasoning" Machine Intelligence, 9, eds., J. E. Hayes, D. Michie, and L. I. Mikulich. New York: Elsevier, pp. 149-194, 1979.
- [20] Wang, Li-Xin; "A Course in Fuzzy Systems and Control", Prentice-Hall International, Inc. 1997.
- [21] Trillas, E. y Gutierrez Ríos, J.; "Aplicaciones de la Lógica Borrosa"; Consejo Superior de Investigaciones Científicas; Madrid, 1992
- [22] Bezdek, J. C. y Pal, Sankar K.; "Fuzzy Models for Pattern Recognition", IEEE Press, 1992.
- [23] Wang, Li-Xin; "Adaptive Fuzzy System and Control. Design and Stability Analysis", Prentice-Hall, Inc. 1994
- [24] Takagi, T. y Sugeno, M.; "Derivation of Fuzzy Control Rules from Yhuman Operator's Control Actions" Proc. IFAC Symp. Fuzzy Information, Knowledge Representation and Decision Analysis, Julio 1983
- [25] Takagi, T. y Sugeno, M.; "Fuzzy Identification of Systems and tis Applications to Modeling and Control"; IEEE Transactions on Systems, Man, and Cybernetics, 15, pp. 116-132, 1985.
- [26] Anderson, James A. y Rosenfeld, Edward, editores; "Neurocomputing Foundations of Research", MIT Press, Cambridge, MA, 1988.
- [27] Benítez, J.M.; Castro, J. L. y Requena, I.; "Las Redes Neuronales Artificiales son Sistemas Difusos Aditivos", V Congreso Español sobre Tecnología y Lógica Fuzzy (ESTYLF'95), pp. 327-329, Murcia, Septiembre 1995.
- [28] Bezdek, J. C.; "Pattern Recognition with Fuzzy Objective Function Algorithms"; Plenum Press, New York, 1981
- [29] Brown, Martin y Harris, Chris; "Neurofuzzy Adaptive Modelling and Control", Prentice-Hall International, 1994.
- [30] Cadenas, J. M.; Gómez-Skarmeta, A.; Camacho, A. M.; Fernández, L. y Martín, F.; "Una Aproximación Sistemática al tratamiento de Conceptos y Cantidades Difusas", V Congreso Español sobre Tecnología y Lógica Fuzzy (ESTYLF'95), pp. 29-34, Murcia, Septiembre 1995.
- [31] Chiu, S.; "Fuzzy Model Identification Based on Cluster Estimation", Journal of Intelligent & Fuzzy Systems, vol. 2, nº 3, Septiembre 1994.
- [32] Falzetti, M.; Mochón, J. y Kumar, S.; "Results and Perspectives of Using Artificial Intelligence Techniques in Blast Furnaces: The FANCIM Project"; Application of Artificial Neural Network Systems in the Steel Industry; ECSC Workshop; pp. 95-104; Enero, 1998.
- [33] Freeman, J. A. y Skapura, D. M.; "Redes Neuronales: Algoritmos, Aplicaciones y Técnicas de Programación"; editorial Addison-Wesley/Diaz de Santos.
- [34] Gulley, Ned y Jang, J.-S. Roger; "Fuzzy Logic Toolbox for Use with MATLAB", The Math Works, Inc., Enero 1995.
- [35] Gupta, M. M.; "Cognitive Information and Neural Computing Systems"; Proc. of the 2nd. Intl. Conf. on Fuzzy Logic; pp. 649-652, Iizuka, Japón, 1992.

- [36] Jang, J.-S. R.; "ANFIS: Adaptive-Network-Based Fuzzy Inference Systems", IEEE Transactions on Systems, Man, and Cybernetics, vol. 23, n° 3, pp 665-685, Mayo 1993
- [37] Jang, J.-S. R.; "Fuzzy Modeling Using Generalized Neural Networks and Kalman Filter Algorithm", Proc. of the Ninth National Conf. on Artificial Intelligence (AAAI-91), pp. 665-685, Mayo 1993.
- [38] Jang, J.-S. R.; "Rule Extraction Using Generalized Neural Networks" Proc. 4th IFSA World Congress; Julio, 1991.
- [39] Jang, J.-S. R.; "Self-Learning Fuzzy Controllers Based on Temporal Back Propagation", IEEE Trans. on Neural Networks, vol. 3; n° 5; pp. 714-723, Septiembre 1992.
- [40] Jang, J.-S. R. y Sun, C.-T.; "Neuro-Fuzzy Modeling and Control"; The Proceedings of the IEEE, vol. 83; n° 3; pp. 378-406, Marzo 1995.
- [41] Johnstone, S. y Taylor, A. G.; "Application of Multivariate Statistical Methods to Blast Furnace Hearth Temperatures"; Application of Artificial Neural Network Systems in the Steel Industry; ECSC Workshop, pp. 69-91; Enero, 1998.
- [42] Krzanowski, W. J.; "Principal Component Analysis in the Presence of Group Structure"; Appl. Statist. 33, pp. 164-168; 1984
- [43] Wang, L.-X. y Mendel, J. M.; "Back-Propagation Fuzzy Systems as Nonlinear Dynamic Systems Identifiers"; Proceedings of the IEEE International Conference on Fuzzy Systems, San Diego, Marzo 1992.
- [44] Wang, L.-X y Mendel, J. M.; "Generating Fuzzy Rules by Learning from Examples", IEEE Transactions on Systems, Man, and Cybernetics, vol. 22, n° 6, pp. 1414-1427, 1992.
- [45] Widrow, Bernard y Stearns, Samuel D.; "Adaptive Signal Processing", Signal Processing Series, Prentice-Hall Englewood Cliffs, NJ, 1985.
- [46] Widrow, Bernard y Winter, Rodney; "Neural Nets for Adaptive Filtering and Adaptive Pattern Recognition", Computer 21 (3): 25-39, Marzo 1988.
- [47] Yager, R. y Filev, D.; "Approximate Clustering via the Mountain Method"; IEEE Transactions on Systems, Man and Cybernetics, 24: 1279-1284, 1994.
- [48] Yager, R. y Filev, D.; "Generation of Fuzzy Rules by Mountain Clustering", Journal of Intelligent & Fuzzy Systems, vol 2, n° 3, pp. 209-219, 1994.
- [49] Aranguren, F. y Mallol, A.; "Siderurgia", Editorial Dossat, S. A, pp. 261-376, 1962.
- [50] Bendat, Julius S. y Piersol, Allan G.; "Random Data: Analysis and Measurement Procedures", Wiley- Interscience, 1971
- [51] Bezdek, J. C.; "Fuzzy Mathematics in Pattern Classification" PhD thesis, Applied Math. Center, Cornell University, Ithaca, 1973.
- [52] Delgado, M.; Gómez-Skarmeta, A. y Martín, F.; "Un Enfoque Aproximativo para la Generación de Reglas mediante Análisis Cluster", V Congreso Español sobre Tecnología y Lógica Fuzzy (ESTYLF'95), pp 43-47, Murcia, Septiembre 1995.
- [53] Hamming, Richard W.; "Digital Filters". Prentice-Hall, Englewood Cliffs, NJ, 1983.

- [54] Lee, C.-C.; "A Self-learning Rule-Based Controller Employing Approximate Reasoning and Neural Net Concepts"; *Int. J. Intelligent Systems*, vol. 5, n° 3, pp. 71-93, 1991.
- [55] Olmeda, Ignacio y Barba-Romero, Sergio; "Redes Neuronales Artificiales: Fundamentos y Aplicaciones", Universidad de Alcalá de Henares, Servicio de Publicaciones, pp. 6-12 y 139-162, 1993.
- [56] Zimmermann, H. J.; "Fuzzy Sets, Decision Making and Expert Systems"; 2ª edición, Kluwer Academic Publishers, Dordrecht-Boston, M.A., 1991.
- [57] J. F. Jiménez Castellanos. 1998 (Tesis Doctoral). Diseño de la zona preparativa de un Horno Alto a escala: aplicación al modelado del sistema de carga y del flujo de gas.
- [58] "La Fabricación del acero", UNESID, SIDEPROF.
- [59] Abhay Bulsari and Henrik Saxén . *Process Metallurgy*. Classification of blast furnace probe temperatures using neural networks.
- [60] N. J. Busby, T. A. T. Fray, and D. C. Goldring. Nature of cohesive zone in blast furnace.
- [61] Technical Report N° 1, British Steel. July 1997. Intelligent Monitoring Systems for Blast Furnace.
- [62] Hiroshi Saito, Yotaro Ohno, Yutuka Yamada and Takori Takbe. *Ironmaking Proceedings*. AIME. Vol 45. 1986. Three dimensional analysis of cohesive zone in blast furnace and its control system .
- [63] I. Kobayashi, S. Inaba and M. Isobe. *Ironmaking Proceedings*. AIME. Vol 43. 1984. Application of Mathematical model estimating cohesive zone in blast furnace.
- [64] Yoshitaka Sawa , Kanji Takeda and Seiji Tajuchi. *Iron and Steel Research Labs*. Kawasaki Steel Corporation. Mathematical modelling of blast furnace characterised by the precise layer structure column.
- [65] Matti seppänen, Rautaruuki Oyj, Corporate R&D. Neural Network modelling for blast furnace process.
- [66] I. Kobayashi, S. Inaba and M. Isobe. Central Research Laboratory. Kobe Steel. Blast furnace phenomena and modelling.
- [67] Mats Nikus and Henrik Saxén . *Process metallurgy*. On- line model of gas distribution in the blast furnace.
- [68] Technical Report. CRM. 1997. Modelling of gas and char flows at high PCI.
- [69] H.W. Gudenau and K. Kreibich. *Scandinavian Journal of Metallurgy* 11. 1982. On the Cohesive Zone Phenomena in the blast furnace .
- [70] Henrik Saxén. *Steel Research* 67 (1996) 73-78. Interpretation of probe temperatures in the blast furnace using polynomial approximations.
- [71] Yudong Cai. *Steel Research* 65 (1994) N°11, 485-487. Optimisation of BOF's lining resistance by application of artificial neural network.
- [72] Unesid 1998. La fabricación del acero.
- [73] S. G. Peacey and W. G. Davenport. *El alto horno de hierro*. Teoría y Práctica.
- [74] ISS Vol56. Chicago, IL 1997. Ironmaking conference proceedings.

- [75] Agustín Martínez Menéndez. Tesis Doctoral. Madrid 1993. Modelo para la automatización del cálculo de las principales características de un horno alto.
- [76] ECSC Workshop. Brussels, 22 and 23 January 1998. Application of Artificial Neural Network Systems in the Steel Industry.
- [77] Martin T. Hagan, Mark Beale, Howard B. Demuth. Neural Network Design.
- [78] Toronto, March 29 April 1981. Vol 40. Proceedings of the 40th Ironmaking Conference.
- [79] Vol 17 Number 7. 1997. Transactions of the Iron and Steel Institute of Japan.
- [80] J. Sjöberg, Linköping University. 1994. Some examples on Identification with Neural Networks.
- [81] J. Zupan and J. Gasteiger. Institut, Technische Universität München. Review. January 1991. Neural Networks: A new method for solving chemical problems or just a passing phase.
- [82] X. Bi, K. Torssell and O. Wijk. ISIJ International 32 (1992) 470-480. Simulation of blast furnace process by a mathematical model.
- [83] Z. Boger. International Symposium on artificial intelligence and expert systems in process industry. India, December 1994, pp. 148-165. Modelling of process plant by artificial neural networks.
- [84] K. Dammert. 1991. New process control technology for iron making.
- [85] N. Kadaba, K. E. Nygard, P. L. Juell. International Joint Conference on Neural Networks, Washington DC, USA. 1989. Modular back - propagation neural networks for large domain pattern classification.
- [86] M. Konishi, Y. Otsuka and M. Konishi. Third European Seminar on Neural Computing, February 1990, The Market Place, London, UK. Application of neural network to operation guidance in blast furnace.
- [87] Julius S. Bendat & Allan G. Piersol "Random Data: Analysis and Measurements Procedures" Wiley-Interscience.
- [88] A. J. Morris & E. B. Martin "Neural Networks – Panacea or Pragmatic solution" ECSC Workshop 1998
- [89] H. Whittaker, M. Hartwig, M. Poschmann & A. Seeliger "The Use of Neural Networks in BOS Process Modelling" ECSC Workshop 1998.
- [90] H. Whittaker, M. Hartwig, M. Poschmann & A. Seeliger "The Use of Neural Networks in BOS Process Modelling" ECSC Workshop 1998.
- [91] Rafal Zbikowski & Kenneth J. Hunt "Neural Adaptive Control Technology" World Scientific Series in Robotics and Intelligent System Vol.15 1996.
- [92] M. Norgaard "Neural Network Based System Identification Toolbox" Tech. Report 95-E-773, Department of Automation, Technical University of Denmark 1995.
- [93] Jerzy Moscinski & Zbigniew Ogonowski "Advanced control with MatLab & Simulink" Ellis Horwood 1995.
- [94] Omid Omidvar & David L. Elliott "Neural System for Control" Academic Press 1995.
- [95] Jerry M. Mendel, "Fuzzy Logic System for Engineering: A Tutorial", IEEE 1995.

- [96] James C. Bezdek and Sankar K. Pal, "Fuzzy Models for Pattern Recognition", IEEE Press, 1992.
- [97] M. Nagai, M. Saino, S. Tamura, K. Kaneda, K. Okabe, K. Fukutake and S. Taguchi. Proceedings of the 36th Ironmaking Conf., ISS - AIME 1997. GO – STOP system applied to blast furnace computer of Chiba works.
- [98] H. Noel and J. Y. Quemeneur. International Neural Networks Conference. Paris, France, July 1990. NHF: Location of thermal loss in blast furnace.
- [99] Alahakoon, D., Halgamuge, S. K., Srinivasan, B. Dynamic self-organizing maps with controlled growth for knowledge discovery. IEEE Transactions on Neural Networks, 11,3,601.614,2000.
- [100] Atiya, A. F., EL- Shoura, S.M., Shaheen, S. I., EI-Sherif, M. Acomparision between Neural Network forecasting techniques- Case study: River flow forecasting. IEEE Transactions on Neural Networks, 10,2,pp.402, 2000.
- [101] Barnden, J. A. Artificial intelligence and neural networks. En [Arbib 98], prate III,pp. 98-102, 1998.
- [102] Benítez, J., Castro, J., Requena, I. Are neural networks black boxes?. IEEE Tran. On Neural Networks, 8 1156-1164, 1997.
- [103] Figueiredo, M., Gomide, F. Design of fuzzy systems using neural networks. IEEE Trans. On Neural Network, 10,4,815-827, 1999.
- [104] Fogelman – Soulié, F. Applications of neural networks. En [Arbib 98], parte III, pp.94 – 98, 1998.
- [105] Gabrielli, A., Gandolfi, E. A fast digital fuzzy processor. IEEE Micro, Vol.9,nº 1, 1999.
- [106] Granado, B., Lacassagne, L., Garda, P. Can general purpose microprocessors simulate neural networks in real-time? Actas del International Work- Conference on Artificial and Natural Neural Networks, IWANN'99, Alicante (España), Junio 1999. LNCE Vol. 1606 y 1607, pp. 21-29, Springer – Verlag, 1999.
- [107] Número especial sobre Neural Networks for Data Mining and Knowledge Discovery, de la revista IEEE Transactions on Neural Networks, mayo 2000.
- [108] Kohonen, T. Kaski, S., Lagus, K.K., Salojärvi, J., Paatero, V., Saarela, A. Organization of a massive document collection. IEEE Transactions on Neural Networks, 11,3,547-585, 2000.
- [109] Kolinummi, P., Hämäläinen, T., Kaski, K. Improving ANN processing with a dedicated hardware systems. IEEE Circuits and Devices Magazine, marzo, 19-27, 1997.
- [110] Li, H.X., Chen, C.L.P. The equivalence between fuzzy logic systems and feedforward neural networks. IEEE Transactions on Neural Networks, 11,2, pp.356-365, 2000.
- [111] Lindsey, C. S. Neural Network Hardware. Lección on-line, noviembre 1998 (<http://www1.cern.ch/NeuralNets/nwInHepHard.html>)
- [112] Martín de Brío, B., Medrano Marqués, N., Hernández, S. A low-cost neuroprocessor board for emulating de SOFM Neural Model. 5th IEEE International Conference on Electronics, Circuits and Systems, ICECS, 98, Lisboa (Portugal), septiembre 1998.

- [113] Medrano Marqués, N. Nuevas Técnicas Hardware y Software para Análisis de Datos con Redes Neuronales. Tesis Doctoral, Universidad de Zaragoza, mayo 1998.
- [114] Nelson, T., Kerridge, B. Neural networks evaluates noise in auto tape decks. *Test & Measurement Europe*, 33-37, abril, 1999.
- [115] Passino, K., Yurkovich, S. *Fuzzy Control*. Addison- Wesley, 1998.
- [116] Vapnik, V. M. An overview of Statistical Learning Theory. *IEEE Transactions on Neural Networks*, 10,5, pp. 988-999, 1999.
- [117] Vesanto, J. SOM-based data visualization methods. *Intelligent Data Analysis*, 3, 111-126, 1999.
- [118] Vesanto, J. Alhoniemi, E. Clustering of the self-organizing map. *IEEE Transactions on Neural Networks*, 11,3, 586-600, 2000.
- [119] Hinnelä, J. and H. Saxén (2001c) "Estimating the burden distribution in the blast furnace with a hybrid model", *Proceedings of the 4th International ICSC Symposium on Soft Computing and Intelligent Systems for Industry*, June 2001, Paisley, Scotland, U.K., pp. 88, CD pp. 49.
- [120] Pettersson, F. and H. Saxén (2001) "A hybrid genetic algorithm for parametric and structural learning in layered neural networks", submitted manuscript.
- [121] Hinnelä, J. and H. Saxén (2001c) "Estimating the burden distribution in the blast furnace with a hybrid model", *Proceedings of the 4th International ICSC Symposium on Soft Computing and Intelligent Systems for Industry*, June 2001, Paisley, Scotland, U.K., pp. 88, CD pp. 49.
- [122] Nikus, M. (2001) A set of models for on-line estimation of burden and gas distribution in the blast furnace, doctoral thesis, Heat Engineering Laboratory, Åbo Akademi University, Finland.
- [123] Pettersson, F., J. Hinnelä and H. Saxén (2002) "Blast furnace burden distribution modelling with an evolutionary neural network", accepted for *International Conference on Advances in Materials and Materials Processing (ICAMMP-2002)*, February 2002, Kharagpur, India.
- [124] Kitson, P. and Mochon, J. (2003) "Optimization of sinter plant operating conditions and B.F. burden material resources using advanced multivariate statistics" *ECSC 2003 proceeding*.
- [125] Jimenez, J. (2004) "Mathematical model of gas flow distribution in a scale model of B.F." *ISIJ International*. Vol 44 N°3 (2004) March.
- [126] Obeso, F. (2004) "B.F. Hot metal temperature prediction through Neural Networks based models. *ISIJ International*. Vol 44 N°3 (2004) March.

UNIVERSIDAD DE ALCALÁ
SERVICIO DE POSTGRADO

DILIGENCIA PARA HACER CONSTAR QUE EL
PRESENTE EJEMPLAR DE LA TESIS PRESENTADA
POR D. Miguel Ángel Júdez
CONSTA DE 127 PÁGINAS Y HA SIDO ENTREGADA
CON FECHA 20 de Julio de 2004
A EFECTOS DE DEPOSITO DE TESIS.

EL FUNCIONARIO

Reunido el Tribunal que suscribe en
el día de la fecha acordó otorgar
a la presente Tesis Doctoral la
calificación de Sobresaliente

con Lode

Alcalá de Henares,

28 de

Julio de

2005

EL PRESIDENTE

Fdo.:

León Spatily Sib

EL SECRETARIO

Fdo.:

Daniel Merat

EL VOCAL

Fdo.:

José Luis Enríquez

EL VOCAL

Fdo.:

Guillermo Gómez Pérez

EL VOCAL

Fdo.:

José Antonio de San