

**UNIVERSIDAD COMPLUTENSE DE MADRID**

FACULTAD DE CIENCIAS QUÍMICAS  
Departamento de Ingeniería Química



**TESIS DOCTORAL**

**Aplicación de simulación y redes neuronales a la industria del  
fibrocemento y del papel**

MEMORIA PARA OPTAR AL GRADO DE DOCTOR

PRESENTADA POR

**Álvaro Alonso Zorita**

Directores  
Carlos Negro Álvarez  
Ángeles Blanco Suárez

**Madrid, 2014**

**UNIVERSIDAD COMPLUTENSE DE MADRID  
FACULTAD DE CIENCIAS QUÍMICAS  
DEPARTAMENTO DE INGENIERÍA QUÍMICA**



**APLICACIÓN DE SIMULACIÓN Y REDES  
NEURONALES A LA INDUSTRIA DEL  
FIBROCEMENTO Y DEL PAPEL**

**MEMORIA**

**Que para optar al grado de Doctor  
por la Universidad Complutense de Madrid presenta**

**D. Álvaro Alonso Zorita**

**2014**



CARLOS NEGRO ÁLVAREZ, CATEDRÁTICO, y ÁNGELES BLANCO SUÁREZ, PROFESORA TITULAR DEL DEPARTAMENTO DE INGENIERÍA QUÍMICA DE LA FACULTAD DE CIENCIAS QUÍMICAS DE LA UNIVERSIDAD COMPLUTENSE DE MADRID

## **INFORMAN**

Que el trabajo de investigación titulado “APLICACIÓN DE SIMULACIÓN Y REDES NEURONALES A LA INDUSTRIA DEL FIBROCEMENTO Y DEL PAPEL”, ha sido realizado bajo su dirección en el Departamento de Ingeniería Química, dentro de los proyectos del Grupo de Investigación de Celulosa y Papel de la Universidad Complutense de Madrid y constituye la memoria que presenta D. Álvaro Alonso Zorita, para aspirar al Grado de Doctor.

Y para que conste a los efectos oportunos, firman la presente, en Madrid a 20 de mayo de 2014

Prof. Dr. Ángeles Blanco Suárez

Prof. Dr. Carlos Negro Álvarez



## AGRADECIMIENTOS

Durante los años que ha supuesto la etapa de elaboración de la presente tesis, he tenido la posibilidad de adquirir una experiencia personal y profesional que me ha ayudado a afrontar multitud de situaciones, creciendo como investigador y como persona. Agradezco a la Universidad Complutense de Madrid y a la Comunidad de Madrid el haber financiado las becas necesarias para la elaboración de la presente tesis. Quiero agradecer también a Holmen Paper Madrid y a Uralita el haberme dado la oportunidad de desarrollar este trabajo en sus fábricas, en colaboración con sus plantillas.

En primer lugar quisiera agradecer a Ángeles y a Carlos la oportunidad que me brindaron de trabajar en el Grupo de Celulosa y Papel del Departamento de Ingeniería Química de la Universidad Complutense de Madrid, desde el proyecto fin de carrera. Su ayuda y consejo han sido la guía con la que me animé a afrontar esta fase de mi vida profesional, y gracias a la cual he conseguido darle forma.

Quisiera agradecer en especial a todos mis compañeros el haberme aguantado todos estos años. La convivencia te deja anécdotas y recuerdos para dar y tomar, y todos los ratos vividos en la 5ª planta, cafetería, pausas de los “fumadores”, etc., son recuerdos que quedarán para siempre. Gracias a Adela, Conchi, Helena, Juanma, Juan Carlos, Antonio, Julio, y el resto de compañeros que han convivido conmigo, y con los que tantas risas nos hemos echado.

Y a José Luis y Rubén solo recordarles que aparte de compañeros de carrera, cofundadores de los TBB&G y ser con los que más ratos he compartido, ya los considero como de la familia, y pese a tomar diferentes rumbos, espero que nos sigamos viendo para “ponernos al día”.

La tesis doctoral representa el fruto de muchos años de estudio, esfuerzo, y de la educación que he recibido. Todo esto quiero agradecerérselo a mis padres, que siempre me han inculcado la importancia del esfuerzo en la vida, y me han transmitido su experiencia.

Mención especial para quien más se ha alegrado y ha sufrido conmigo todos estos años, apoyándome en los momentos más difíciles, que comenzó siendo mi novia y ya es mi mujer y madre de Santi. ¡Gracias Laurita! Tu apoyo ha sido fundamental en muchos aspectos de mi vida, y en particular para la elaboración de esta tesis, que quiero dedicar a Santi, mi pequeño diablillo, como símbolo de la satisfacción que da el realizar un trabajo, corregir continuamente tus errores, y ver los resultados del esfuerzo.

## COMENTARIOS PREVIOS

En el presente trabajo, se ha decidido aplicar notación decimal de punto (anglosajona), debido a la utilización de diferentes programas que trabajaban en este entorno, lo cual obligó al empleo generalizado de este sistema en la conversión de datos y generación de gráficos específicos de dichos programas.

Algunos de estos programas incluso no permitían la elección del castellano en la creación de figuras, con lo cual se ha decidido mantener el aspecto original de las mismas, con la traducción de aquellos datos o aspectos relevantes para la interpretación del trabajo realizado.

La terminología anglosajona, tan ampliamente difundida, determina en algunos casos una nomenclatura de común empleo y complicada en su traducción. Se ha intentado entrecomillar todo término utilizado sin traducción al castellano.

Otro término bastante problemático actualmente es el de “*simulación*”. Según la Real Academia Española de la lengua (RAE) se entiende por simulación, en su acepción más adecuada, a la acción de simular, que es representar algo, fingiendo o imitando lo que no es. Saber qué se entiende exactamente por simulación no es una tarea sencilla, ya que engloba desde el empleo de simples fórmulas matemáticas, sin ninguna interfaz gráfica, hasta los más potentes programas informáticos.

En la presente tesis se ha empleado el término “simulación” en el caso de la representación de procesos de fabricación a través de diagramas virtuales. También se ha utilizado para definir los resultados obtenidos con los modelos previamente creados y con datos no empleados anteriormente en su desarrollo. Cuando esta obtención de resultados se utiliza en la fase de creación del modelo, y con datos diferentes a los empleados en el desarrollo del modelo, como un criterio de elección, se habla de validación en vez de simulación.

## ÍNDICE

<b>EXTENDED ABSTRACT.....</b>	<b>7</b>
Introduction .....	7
Research description.....	7
Conclusions.....	10
<b>RESUMEN .....</b>	<b>12</b>
<b>1.    DEFINICIÓN DE LOS OBJETIVOS.....</b>	<b>13</b>
Objetivos para la fabricación de fibrocemento .....	16
Objetivos para la fabricación de papel.....	16
<b>2.    PROCESOS INDUSTRIALES.....</b>	<b>18</b>
<b>2.1.    Proceso de fabricación del fibrocemento .....</b>	<b>18</b>
2.1.1.    Procesos industriales.....	19
2.1.1.1.    Problemática del empleo de celulosa en la fabricación de fibrocemento.....	21
2.1.1.2.    Importancia del control .....	23
2.1.2.    Propiedades.....	24
<b>2.2.    Proceso de fabricación del papel.....</b>	<b>27</b>
2.2.1.    Procesos industriales.....	28
2.2.1.1.    Importancia del control .....	31
2.2.2.    Propiedades.....	32
<b>3.    HERRAMIENTAS DE MODELADO MATEMATICO .....</b>	<b>35</b>
Técnicas clásicas.....	35
Modelos físico-químicos determinísticos.....	35
Tratamiento avanzado de datos .....	36
<b>3.1.    Principales métodos de tratamiento avanzado de datos .....</b>	<b>37</b>
3.1.1.    Métodos de análisis multivariable .....	37
3.1.2.    Métodos “Data Mining”.....	39
3.1.3.    Redes neuronales.....	40
3.1.3.1.    Tipos de redes.....	41
3.1.3.2.    Funcionamiento.....	45
3.1.4.    Algoritmos de retropropagación “Backpropagation” .....	46
3.1.5.    Parámetros especiales de los algoritmos empleados .....	52
<b>4.    ANTECEDENTES .....</b>	<b>54</b>
<b>4.1.    Aplicaciones de las redes neuronales.....</b>	<b>54</b>
4.1.1.    En la industria del fibrocemento .....	54
4.1.2.    En la industria pastero-papelera.....	54
4.1.2.1.    Desintegradores de pasta y digestores .....	56
4.1.2.2.    Lavado de pasta.....	59
4.1.2.3.    Blanqueo.....	61
4.1.2.4.    Destintado.....	62
4.1.2.5.    Mezclado.....	63
4.1.2.6.    Refino.....	63
4.1.2.7.    Calderas, emisiones y corrientes residuales.....	67
4.1.2.8.    Lavado de gases/líquidos .....	71

4.1.2.9.	Parte húmeda de la máquina de papel .....	71
4.1.2.10.	Sección de prensado.....	73
4.1.2.11.	Parte seca de la máquina.....	74
4.1.2.12.	Calandrado.....	75
4.1.2.13.	Roturas de la hoja .....	75
4.1.2.14.	Calidad del papel.....	75
4.1.2.15.	Otras aplicaciones.....	79
4.1.2.16.	Tendencias / Economía.....	82
4.1.2.17.	Energía.....	83
4.1.2.18.	Trabajos matemáticos.....	83
4.1.2.19.	Alternativas .....	85
4.1.3.	Beneficios económicos publicados de las redes más utilizadas.....	85
<b>4.2.</b>	<b>Herramientas para el desarrollo de redes neuronales.....</b>	<b>87</b>
<b>4.3.</b>	<b>Herramientas para la simulación de procesos.....</b>	<b>92</b>
<b>4.4.</b>	<b>Programas para el análisis y procesamiento de datos.....</b>	<b>95</b>
<b>5.</b>	<b>MATERIALES Y MÉTODOS .....</b>	<b>96</b>
<b>5.1.</b>	<b>Materiales.....</b>	<b>96</b>
5.1.1.	Fábricas .....	96
5.1.2.	Materias Primas.....	96
<b>5.2.</b>	<b>Equipos y Software .....</b>	<b>97</b>
5.2.1.	Sensor de floculación.....	98
5.2.2.	Desarrollo de redes neuronales.....	103
5.2.3.	Simulación de procesos industriales .....	107
5.2.4.	Análisis y procesamiento de datos.....	109
<b>5.3.</b>	<b>Métodos de trabajo.....</b>	<b>110</b>
5.3.1.	Matlab.....	110
5.3.2.	Extend (FlowMac).....	111
5.3.3.	Metodología de la investigación.....	112
5.3.3.1.	Fibroceamento .....	118
5.3.3.2.	Papel .....	119
<b>6.</b>	<b>RESULTADOS Y DISCUSIÓN.....</b>	<b>121</b>
<b>6.1.</b>	<b>Producción de fibroceamento .....</b>	<b>125</b>
6.1.1.	Obtención de regresiones polinómicas .....	125
6.1.2.	Obtención de regresiones fijando la densidad en tierno constante .....	127
6.1.3.	Obtención de redes neuronales para fibroceamento.....	130
6.1.3.1.	Resultados experimentales e interpretación .....	130
6.1.3.1.1.	Red neuronal "A".....	130
6.1.3.1.2.	Red neuronal "B".....	134
6.1.3.1.3.	Red neuronal "C".....	139
6.1.3.1.4.	Red neuronal "D" .....	141
6.1.3.1.5.	Red neuronal "E".....	144
6.1.3.1.6.	Red neuronal "F" .....	148
6.1.3.2.	Recomendaciones obtenidas .....	151
<b>6.2.</b>	<b>Producción de papel .....</b>	<b>154</b>
6.2.1.	Optimización de la calidad del papel .....	154
6.2.1.3.	Procesado previo de los datos.....	155
6.2.2.	Primera selección de variables .....	163
6.2.3.	Análisis estadístico .....	164
6.2.4.	Propuesta de técnicas de modelado.....	167
6.2.4.1.	Regresiones múltiples mensuales.....	167

6.2.4.2.	Regresión múltiple de cuatro meses .....	169
6.2.4.3.	Redes neuronales artificiales .....	171
6.2.5.	Definición del esquema de modelado.....	173
6.2.6.	Modelado preliminar.....	175
6.2.7.	Estudio completo .....	182
6.2.8.	Segunda selección de variables.....	192
6.2.9.	Modelado “de optimización” .....	193
6.2.10.	Actualización/mejora de los modelos .....	194
6.2.11.	Automatización de todas las tareas anteriores .....	197
6.2.12.	Tareas relacionadas (entrenamiento de operarios, implementación del modelo).....	198
<b>7.</b>	<b>DESARROLLO DE PROGRAMAS.....</b>	<b>199</b>
<b>8.</b>	<b>CONCLUSIONES .....</b>	<b>200</b>
8.1.	Mejoras en la optimización de la fabricación de fibrocemento.....	200
8.2.	Mejoras en la optimización de la fabricación de papel .....	201
<b>BIBLIOGRAFÍA .....</b>		<b>CCIV</b>
<b>ÍNDICE DE FIGURAS Y TABLAS .....</b>		<b>CCXVII</b>
<b>ANEXOS</b>	<b>CCXXII</b>	

## **EXTENDED ABSTRACT**

This PhD Thesis is entitled: “The use of Neural Networks and Simulation in the Fiber-Cement and Pulp and Paper industries”

### **INTRODUCTION**

This PhD Thesis presents the use of artificial neural networks as optimization tools in both fibre cement and pulp and paper industries.

This study reflects the success of combining Focused Beam Reflectance Measurement (FBRM) sensor and Artificial Neural Networks (ANN) to make predictions for product properties, in order to optimise the industrial processes. The inputs of the networks are the FBRM sensor measurements and other different measurements acquired at the mills. The outputs are final product properties, related to product resistance. With this work, a good prediction of final properties has been achieved. The conclusions reached with the analysis of the results of neural networks can be used in establishing optimal process conditions. The obtained results demonstrate that ANNs can be used as reliable soft sensors for predicting product quality.

### **RESEARCH DESCRIPTION**

This work has been carried out at Uralita’s fiber-cement line 3 placed at Valladolid, and the Holmen Paper Madrid PM61 Mill at Fuenlabrada (Madrid).

Fiber cement trials were performed on an industrial Hatschek machine with four vats working at 60-65 m/min producing fibre cement sheets from a mixture of highly refined unbleached Kraft pulp (3%), poly-vinyl-alcohol (PVA) fibres (2%) and silica fume (6%) on a matrix of ASTM Type II A cement (89%).

42 to 48.8 g/m<sup>2</sup> Newsprint Paper from 100% recycled fibers has been selected at the paper mill in order to test the models.

Fibre cement production consists of the following main steps: raw material mixing, sheet formation, pressing, moulding/sizing, curing and finishing. Flocculation is critical at the sheet formation step, which occurs in sieve cylinders. The best location for a sensor to monitor the flocculation process is the inlet of the vat, where the primary thin fibre cement layer is formed on the Hatschek machine. This is the place where the flocculant has just been added and, therefore, the effects will be seen quickly.

Main steps in papermaking are:

- Stock preparation: This is the section where the furnish is prepared and diluted. It implies several steps usually for pulping, removal of contaminants, storage, refining and regulation of consistency.
- The paper machine. It consists of the headbox, the forming section, the press section, the dryer section, the calender and the reel, where final paper is obtained. Wet end is the section where the diluted pulp suspension is uniformly distributed on the forming fabric, for dewatering in order to get the formation of a wet sheet. The wet sheet is later on pressed and dried. Main usual steps related as wet end are the headbox, the forming section and the press section.
- Finally, the roll finishing operation, where paper is prepared for shipping.

For carried out measurements, a commercially available non-imaging scanning laser microscope (or FBRM system), the LASENTEC FBRM M500P, has been used. The FBRM software allows particle size distributions and their evolution with time to be analysed. From the size distribution different statistical values are obtained. These may be the mean size, the median size, size intervals of particles, etc. All the measurements can be averaged over time, to avoid isolated peaks. Measurements are saved with the date and time and this fact allows us to have correlated FBRM data and breaking load or bending strength values of the final product.

This FBRM device has been installed on-line in the sieve cylinders at the fiber-cement plant and in the headbox at the paper machine. These locations have been optimized in order to detect small changes at flocculation processes.

The fibre cement properties analysed are: breaking load after 48 hours (N/m), breaking load after 7 days (N/m), bending strength after 7 days (N•m/m), thickness after 48 hours (mm), thickness after 7 days (mm), density after 7 days (kg/L) and wet sheet density, after forming roll (kg/L). These properties were measured according to EN 494.

The paper properties analysed are longitudinal breaking load (kN/m), longitudinal breaking length (km), formation index, brightness (%), opacity (%) and ash content in pope (%).

At the fiber-cement plant, the developed neural networks are able to distinguish clearly between predictable and non-predictable outputs. Good correlations are obtained for predictable outputs like breaking loads (R correlation coefficients over 0.8) and bending strength (R=0.74). Poor correlations are obtained for variables that could be affected by the operators like the thickness, demonstrating the robustness of the developed neural networks.

## CONCLUSIONS

In the fibre cement industry, the following conclusions have been achieved:

- The total number of counts and the counts in the range between 10-32  $\mu\text{m}$  are the most important statistic from the FBRM sensor to predict fibre cement properties.
- The developed neural networks are able to distinguish clearly between predictable and non-predictable outputs. Good correlations are obtained for predictable outputs like breaking loads (with correlation coefficients up to 0.82 and 0.88) and bending strength (R up to 0.74). Poor correlations are obtained for variables that could be affected by the operators like the thickness (correlation coefficients are 0.48 and 0.14) demonstrating the robustness of the developed neural network.
- Developed ANNs have shown good prediction capabilities even for the manufacture of different mould sheets.

The conclusions for the pulp and paper industry also show the success in the use of ANNs:

- At the paper mill, validation data containing between 40% and 60% of data from external periods of time (different from training data) have been considered optimum in order to develop the models.
- Levenberg-Marquardt algorithm has been selected, and ANNs with 3-7 hidden neurons in one hidden layer have been considered as optimum.
- The optimum training period for this industry have been initially set to 3 months.
- Robust models have been developed to predict paper properties based on wet-end analysis, with 9.0% mean error when predicting

longitudinal breaking load, 7.6% for longitudinal breaking length and 4.4% when predicting formation index. Robustness has been demonstrated with two simulations at different time periods.

- A new automatic methodology for developing ANNs, selecting the best ones and analysing the results, has been successfully developed and applied.
- Thus, developed methodology has allowed reaching robust results in different industries. The use of these techniques, in order to improve product quality, goes beyond the state of the art in both the optimization at the vacuum sieve cylinders, where the primary fiber-cement layer is formed, and the paper mill wet-end chemistry optimization using FBRM.
- Results show that used techniques are highly recommended for these issues, and show their potential as on-line virtual sensors.

## RESUMEN

En esta tesis doctoral se plantea el empleo de redes neuronales como herramienta de optimización en las industrias del fibrocemento y del papel.

En la fabricación de fibrocemento los resultados muestran que, mediante el empleo de un sensor de reflexión de haz enfocado en la suspensión previa a la formación de la lámina primaria, se han desarrollado modelos que predicen la calidad con un índice de correlación  $R$  de 0.80 para el índice de clase a 48 horas y 7 días, de 0.74 para el momento flector a 7 días, y de 0.81 para la densidad a los 7 días, lo que supone un gran avance, al no tener que esperar 7 días para tener los ensayos más fiables de calidad, y poder establecer un control activo de calidad en tiempo real, lo cual le ha valido a esta tesis un reconocimiento a nivel internacional por parte de la industria del fibrocemento y otros materiales compuestos con fibras, en la conferencia IIBCC de 2008.

En la producción de papel, se predice la calidad del producto final a partir de medidas tomadas en la parte húmeda de la máquina de papel, utilizando un sensor laser de reflexión de haz enfocado. Las redes neuronales permiten predecir la calidad del papel con un error medio del 9.0% en la carga de rotura longitudinal, del 7.6% en la longitud de rotura longitudinal, y del 4.4% en el índice de formación. Estos errores se han mantenido, después de 6 meses y cambios sustanciales en la fábrica, en valores del 13%, 17% y 9% respectivamente, lo cual, unido al desarrollo de un sistema de validación automática de los modelos, da valor a su empleo como sensores virtuales. En la industria del fibrocemento se realiza un trabajo análogo, tomando las medidas en la suspensión previa a la formación de la lámina primaria de producto.

Por tanto, se ha definido una metodología de trabajo que permite la obtención de resultados de alta calidad de una forma fiable en diferentes industrias. En los dos casos estudiados, el empleo de estas técnicas resulta novedoso, suponiendo un avance en el estado del arte. La optimización llevada a cabo de la mezcla de entrada a los tanques de formación de láminas primarias de fibrocemento, así como la optimización de la química de la parte húmeda de la máquina de papel empleando el sensor de reflexión de haz enfocado FBRM, ambas con el fin de incrementar la calidad del producto, muestran el potencial de estas técnicas y su idoneidad para los problemas afrontados.

## 1. DEFINICIÓN DE LOS OBJETIVOS

La aplicación de la inteligencia artificial a la industria es un hecho que, ayudado por el reciente desarrollo de la informática, ha permitido obtener modelos matemáticos mediante técnicas diferentes a las clásicas. El nombre de inteligencia artificial viene de la relación existente entre los algoritmos empleados para el desarrollo de los citados modelos y el funcionamiento de diversos sistemas en la naturaleza. Dicho de otra forma, las diferentes técnicas de las que se habla tratan de imitar a la naturaleza en la forma de desarrollarse, convirtiendo procesos naturales como el aprendizaje o la genética en procesos matemáticos. Por ejemplo, el proceso natural de aprendizaje a través de los sentidos se puede transformar en un proceso matemático, a partir de diferentes señales. Esto consiste en la evaluación sistemática de todo tipo de escenarios, mejores y peores, previamente evaluados con sensores de distinto tipo, para que el modelo “aprenda” qué es lo que hace que un escenario sea mejor que otro, por compleja que sea la relación.

Obviamente, aquellos fenómenos que no se pueden explicar mediante las variables evaluadas no se podrán predecir. Por ejemplo, si a un niño se le reprende cada vez que los padres pierden en un juego de azar y el niño no sabe nada de ese juego, nunca podrá entender por qué le reprenden, e intentará entenderlo fallidamente a partir de otros hechos como, por ejemplo, su comportamiento.

Actualmente, en la industria, los procesos tienden a controlarse cada vez con mayor detalle. Los controles se realizan a partir de todo tipo de medidas, las cuales en la actualidad se encuentran muy desarrolladas. Toda medida de una propiedad o variable se basa en la relación de lo que se quiere medir con una propiedad física fácilmente medible. Cuando esto no es posible, es cuando se recurre a la medición indirecta a partir de otras medidas ya tomadas. Para estos casos, la predicción y posterior control de aquello que se desea, a partir de todo tipo de datos y medidas de variables del proceso, es una solución que puede desembocar en mejoras de la fabricación o de la calidad de un producto.

El problema se traslada entonces de buscar un sistema de medida para una propiedad o variable concreta, a obtener, a partir de los datos de los que se disponga, aquello que se desea medir. Para ello, se necesita encontrar correlaciones entre los datos medidos y los que se desean predecir a partir de aquellos. En este contexto, entran en juego diferentes técnicas matemáticas de modelado. Desde los métodos clásicos hasta la inteligencia artificial, todos, a priori,

son métodos cuya validez o idoneidad dependerá del comportamiento del proceso. Se tendrán, por tanto, procesos en los que dichas correlaciones puedan ser simplemente correlaciones lineales, y por otro lado procesos pseudocaóticos, en los cuales solo el empleo de técnicas iterativas de reconocimiento de patrones complejos no-lineales de comportamiento, como pueden ser las redes neuronales, puede permitir una predicción suficientemente exacta de lo que se necesita conocer.

En esta tesis doctoral se estudian dos tipos de industria que presentan algunas similitudes en sus procesos de fabricación. Estas dos industrias son la industria papelera y la del fibrocemento. En ambos casos se forma una lámina de producto a la que se le va eliminando agua, hasta alcanzar, a partir de una suspensión diluida de materias primas, la humedad final deseada. La dilución inicial es necesaria para obtener una buena homogeneización de las materias primas y una buena distribución de las mismas en el producto final.

En el caso del papel, la proporción de fibras en la suspensión es mucho mayor, mientras que en el fibrocemento dominan las cargas minerales. Otra similitud reside en el empleo de floculantes en ambas industrias previamente a la formación de las hojas o placas, dependiendo del caso. Los floculantes son los encargados de aglomerar las cargas minerales, para tener una distribución de tamaños de partículas tal que optimice tanto la retención de partículas sólidas en los productos formados, como la velocidad de drenaje del agua sobrante, a la vez que se obtienen productos de alta calidad y buena formación.

Un mejor conocimiento de los fenómenos físico-químicos existentes en los procesos de floculación y de su influencia en los procesos de retención, formación y drenaje, tanto en la fabricación de papel como de fibrocemento, permitirían mejorar la producción de ambos productos. Para ello se dispone, aparte de las medidas disponibles en cada fábrica, de un sensor láser de medida de reflexión de un haz enfocado (FBRM), diseñado y utilizado originalmente para el control de procesos de cristalización, cuya metodología ha sido adaptada para optimizar el proceso de floculación (Fuente E., 2004; Blanco A., 1994)

También se dispone de diferentes programas de simulación de procesos, aplicados especialmente a la fabricación de papel. Uno de estos programas (FlowMac, conjunto de subrutinas y bloques programados dentro del simulador

Extend, específico para la industria papelera) se ha reprogramado y adaptado para poder simular también una fábrica de fibrocemento.

Con estas herramientas y las matemáticas, por medio de la inteligencia artificial, y más en concreto las redes neuronales, que se describirán con detalle posteriormente, se desarrolla un esquema de trabajo que permite combinar la simulación de los procesos industriales de producción de papel y fibrocemento, con la predicción de importantes propiedades finales de los productos. Por otra parte, también se intenta medir indirectamente, en línea, la composición por componentes de distintas corrientes de estos procesos, mediante medidas tomadas con el sensor FBRM.

El esquema del trabajo realizado se presenta en la figura 1.1, donde se aprecia la conexión entre las distintas tareas realizadas. Una de las diferencias más notables a la hora de afrontar ambos escenarios ha sido la cantidad de datos disponibles en una y otra industria. Mientras en la fábrica de papel se cuenta con un sistema moderno de adquisición de datos con miles de variables incluidas en el mismo, en la fábrica estudiada de fibrocemento, sin tal nivel de modernización, se ha dispuesto de una pequeña cantidad de datos, que ha habido que informatizar. Esto, lógicamente, diferencia los objetivos a conseguir en ambas industrias.

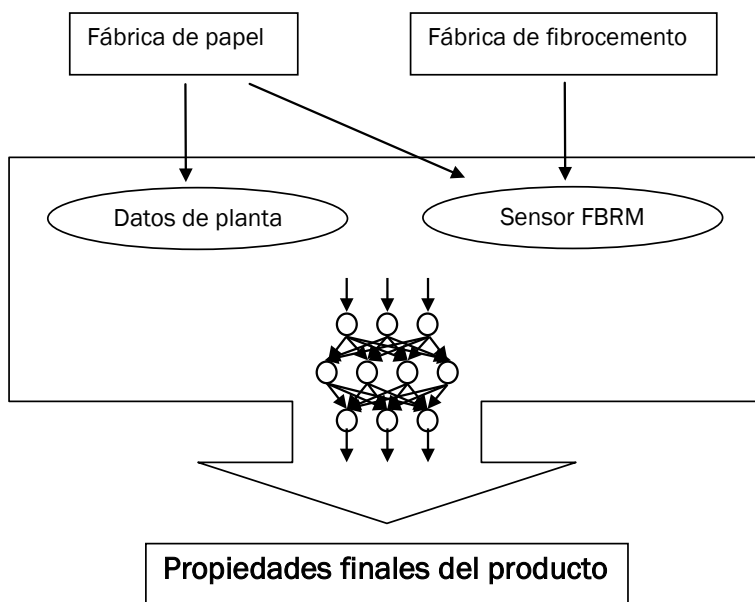


Figura 1.1 - Esquema de trabajo de la tesis doctoral.

Los objetivos aquí expuestos se razonarán convenientemente en los apartados de descripción de los procesos, antecedentes y obtención de resultados. A modo de resumen, se definen los siguientes:

### **OBJETIVOS PARA LA FABRICACIÓN DE FIBROCEMENTO**

La línea principal de investigación ha consistido en la predicción de la calidad del producto final a partir de los datos disponibles, con el fin de tener un sistema inmediato de control de la calidad del producto y, por tanto, ahorrar costes por producción fuera de especificaciones. El objetivo final es, por tanto, el incremento de la productividad y/o el incremento de la estabilidad en la calidad del producto.

Si se tiene en cuenta la zona del proceso donde se ha centrado la investigación, el objetivo se puede definir como: **La optimización de la mezcla de entrada a los tanques de formación de láminas primarias, con el fin de mejorar la calidad del producto.** Ello ha requerido la creación de diferentes modelos que predicen las propiedades del fibrocemento a partir de medidas principalmente obtenidas mediante el sensor de floculación FBRM.

Se ha favorecido la creación de modelos versátiles y robustos para varios tipos de producto, de forma que su aplicación sea sencilla, y sirvan para obtener un conocimiento que permita, a medio plazo, conocer la físico-química existente en el proceso del fraguado del cemento en presencia de cantidades importantes de fibra orgánica y diversos agentes químicos, encargados de mejorar la afinidad de ambos compuestos y mejorar las condiciones de operación.

### **OBJETIVOS PARA LA FABRICACIÓN DE PAPEL**

La línea principal de la investigación ha consistido de nuevo en este caso en la predicción de la calidad del producto final a partir de los datos disponibles (obtenidos con el sistema WinMOPS, que se describirá más adelante), con el fin de definir mejoras potenciales para la optimización del proceso basada en el incremento de su estabilidad. El objetivo final es, por tanto, el incremento de la

productividad y/o el incremento de la estabilidad en la calidad del producto, como en la industria del fibrocemento, pero aplicado a fines ligeramente distintos.

Teniendo en cuenta la zona del proceso en la que se ha centrado la investigación, el objetivo se puede definir más concretamente como: **La optimización de la química de la parte húmeda de la máquina de papel, con el fin de mejorar la calidad del producto.** Ello ha requerido la creación de diferentes modelos que predicen las propiedades del papel a partir de medidas de la sección por optimizar.

Al ser un objetivo a medio plazo, e intentando dar un primer paso para un conocimiento más profundo de la físico-química del final de la parte húmeda de la máquina de papel, se ha decidido optar por un esquema de modelado que favorezca la robustez de los resultados en periodos largos de tiempo, y permita generalizar el comportamiento del sistema.

Como se puede observar, existe un evidente paralelismo en los objetivos a conseguir, lo que, unido a las diferencias entre la cantidad de datos disponibles y a las diferencias intrínsecas entre ambos procesos, convierte la presente tesis en un amplio estudio de la posibilidad de aplicación de técnicas como las redes neuronales en dos campos tan representativos de la industria química.

## 2. PROCESOS INDUSTRIALES

La presente tesis es una aplicación en la industria de técnicas de modelado matemático avanzadas, como las redes neuronales, para profundizar en el conocimiento de los procesos y de esta forma mejorar su control. La aplicación práctica a dos sectores industriales con procesos comunes, pero muy diferentes en otros aspectos, muestra cómo la naturaleza de cada proceso y la disponibilidad de métodos de medida de diferentes variables determinarán, no solo los objetivos a definir en cada caso, sino la calidad de los resultados obtenidos.

### 2.1. PROCESO DE FABRICACIÓN DEL FIBROCEMENTO

Se define al fibrocemento, desde el punto de vista técnico, como aquel material formado sustancialmente por cemento y que está reforzado por un material fibroso que le confiere las propiedades adecuadas para su utilización como material de construcción de diversos elementos. Desde el punto de vista de su composición, se puede definir como una mezcla heterogénea de cargas minerales, fibras y aditivos. Es en las fibras donde se ha introducido un cambio de composición que requiere la optimización del proceso, ya que el empleo de fibras alternativas al amianto hace que deban añadirse aditivos para estabilizar y flocular la mezcla, y así obtener un fibrocemento de mejores propiedades.

La definición de fibrocemento según la R.A.E. muestra el concepto más tradicional, que ha de ser reemplazado para evitar un posible rechazo social: "Mezcla de cemento y fibra de amianto, que se emplea para la fabricación de planchas, tuberías, depósitos, etc."

Su principal aplicación es como material de construcción, en fachadas, tejados e interiores.

Un empleo muy conocido de este material, pero ya no comercializado, debido a la necesidad del empleo de amianto como fibra, es la de material para tuberías de conducción, principalmente de agua, en el intervalo de longitudes de diámetro de 10 a 50 cm. En este caso, la sustitución obligada por ley del amianto por otras fibras alternativas, de las que la celulosa es la que se impone (Soroushian, P. y Marikunte, S., 1990), hace que este uso no se pueda llevar a cabo, debido a la imposibilidad de utilizar para este fin las operaciones de prensado o autoclavado

del nuevo fibrocemento. Por tanto se están introduciendo en el mercado otros materiales para esta aplicación, ampliamente conocida.

Esta sustitución del amianto, como se ha comentado, es debida a motivos legislativos (Orden de 7 de Diciembre de 2001), como resultado de los estudios que se han realizado sobre los efectos negativos de este tipo de materiales sobre la salud de las personas. El empleo de fibras y materiales sustitutivos de los amiantos ha sido objeto de estudio de numerosos artículos, y en la actualidad las plantas se han reconvertido utilizando fibras de celulosa, de vidrio o sintéticas (Coultts, R., 1995).

Anteriormente a esta etapa, existían trabajos que negaban la posibilidad del empleo de celulosa (Krenchel, H., 1972), refutados posteriormente por la práctica industrial. En los años noventa se presentaron trabajos que evaluaban la conversión de las líneas de producción clásicas, entonces con amianto, a las entonces vanguardistas con celulosa (Anon P., 1990).

### **2.1.1. Procesos industriales**

La fabricación del fibrocemento tiene lugar mediante un proceso, basado en el diseño original de Hatschek, en el que una mezcla de fibras y cargas minerales es aspirada por cilindros y tamices, para ser depositada en un fieltro, donde se desgota por la acción del vacío y, posteriormente, se comprime con el rodillo formador, dando como resultado una lámina multicapa, que se conformará para darle al producto la calidad deseada. Finalmente, se procede a un curado en túnel. (Manual de URALITA, 1995).

En la fabricación sin amianto se debe introducir una etapa de prensado y autoclavado, según la tecnología desarrollada por la empresa James Hardie & Co.

Las etapas de la fabricación son, por tanto:

- Preparación de las materias primas (celulosa, sílice, cemento y aditivos).
- Mezcla y dilución de la suspensión.
- Formación de la lámina primaria.
- Formación de la placa.

- Ondulación y prensado.
- Curado en túnel y autoclavado.

Un esquema de la formación de la placa de fibrocemento se puede ver en la figura 2.1.

La problemática surgida en la fabricación a partir de la introducción de la celulosa como fibra integrante del fibrocemento en lugar del amianto, consiste en que la afinidad entre las fibras de celulosa y el cemento es muy diferente a la afinidad que en su momento había con las fibras de amianto, con lo que se hace necesaria la floculación, y de momento no existen sistemas que garanticen un control en continuo fiable de las propiedades finales del producto obtenido. Estas propiedades son controladas mediante medidas en discontinuo de la densidad en tierno del material.




Figura 2.1 - Esquema de la etapa de formación de la placa de fibrocemento.

Las propiedades finales del fibrocemento dependen de la composición de la suspensión previa a la formación de la capa primaria. La distribución de tamaños de partícula (de los flóculos formados) en esta suspensión se puede controlar mediante cambios en la dosificación de floculante, según se ha demostrado en trabajos previos realizados en nuestro Grupo de Investigación. Por otro lado, también se ha

demostrado la utilidad de la sonda FBRM para optimizar el proceso de floculación, cuyos fundamentos y funcionamiento se explicarán más adelante (San Pío I., 2003). En la presente tesis doctoral se resuelven dos aspectos que permiten la instalación en continuo de este sistema de control:

- Primeramente, antes de la realización de esta tesis doctoral no se conocía con detalle la relación existente entre los diferentes tamaños de partícula y las distintas propiedades finales medidas del fibrocemento. Los estudios previos realizados han revelado un comportamiento prácticamente caótico, con relaciones complejas que no han sido resueltas hasta el momento, con coeficientes de correlación  $R^2$  que raramente sobrepasan el valor de 0.5. El empleo de técnicas avanzadas de análisis de datos permite, a través de los resultados, ahondar en el conocimiento de estas relaciones para, en el futuro, intentar encontrar una explicación fisicoquímica al comportamiento hallado.
- El segundo problema es, una vez conocidas estas relaciones, indicar qué distribución de tamaño de flóculos sería la óptima para las propiedades del fibrocemento, lo cual es de un gran interés industrial, ya que regulando la dosis y el tipo de floculante adicionado, resulta viable controlar esa distribución de tamaños.

La dificultad estriba en la actualidad en que para determinar esta relación se deben emplear correlaciones o sistemas con un gran error de estimación. En la presente tesis, mediante el uso de sistemas matemáticos estadísticos y de análisis de datos, se plantea el camino a seguir para solventar los problemas existentes, llegando a tener un sistema fiable de control, a partir de predicciones con un error mucho menor que el que actualmente se tiene, que sea instalable industrialmente, y que permita mejorar la economía del proceso.

### **2.1.1.1. Problemática del empleo de celulosa en la fabricación de fibrocemento**

La celulosa es el material que se impuso en su día como sustituto del amianto, por sus cualidades ventajosas respecto a otras fibras (Soroushian, P. y Marikunte, S., 1990; Bezerra E.M. y col., 2004; Fuente E. y col., 2008). Sin embargo, esto presenta numerosos problemas a la fabricación de fibrocemento.

Las fibras de celulosa, por sí solas, presentan poca afinidad por las cargas minerales del cemento, por lo que han de añadirse aditivos para mejorar la retención. Estos aditivos forman puentes entre la fibra de celulosa y las cargas a retener, de forma que se salva el inconveniente de la baja afinidad entre ambas. Se podrían incluir entre estos aditivos, como parte destacada de la fabricación, los floculantes, que también controlan la retención y el drenaje de la suspensión.

Esta falta de afinidad viene agravada por una gran diferencia entre las densidades de las fibras de celulosa y las cargas minerales del cemento. Se han propuesto distintas opciones de modificación del proceso respecto al que se empleaba con amianto, para subsanar la menor capacidad de la celulosa para formar una matriz adecuada.

- El caudal de pasta en contacto con el tamiz ha de ser mayor, por tanto se hace circular una mayor cantidad de agua en el circuito, con lo que debe controlarse más cuidadosamente la concentración en diferentes puntos del sistema. Con esta medida se complica el cierre de los circuitos de agua y se necesitan equipos nuevos para diluir la pasta y recircular el agua.
- Otra forma de mejorar el proceso, además de la anterior, es refinar las fibras de celulosa para mejorar su capacidad de enlace, maximizando su superficie específica.
- Se requiere, por todo lo visto, un mayor capital inmovilizado en la instalación de producción de fibrocemento, así como el empleo de nuevas materias primas y aditivos. El menor coste de las materias primas necesarias para la fabricación de fibrocemento con celulosa es solo una pequeña atenuación de los inconvenientes que el cambio ha supuesto.
- La celulosa tiene que ser tratada previamente, para mantener unas propiedades constantes y óptimas, con lo que se genera de nuevo una situación de desventaja respecto a la fabricación con amianto.

La celulosa, por otra parte, tiende a retener humedad. Este problema puede resolverse con una elección correcta de los floculantes y añadiendo una etapa de prensado de la placa formada mediante rodillos, si fuese necesario. Dependiendo del tipo de cemento empleado, la humedad sobrante podría reaccionar en el fraguado del cemento, con lo que se genera un sistema complejo de reacciones que

no entran en el campo de estudio de la presente tesis, y que presentarán una gran influencia sobre el producto final.

Este problema, de solución compleja, ha intentado aislarse mediante el empleo de un mismo tipo de cemento en toda la experimentación, así como de un mismo tipo de producción con fibras de alcohol polivinílico (PVA).

En la etapa de curado del fibrocemento, la presencia de materia orgánica impide el fraguado del cemento, con lo que se hace necesario el empleo de nuevas materias primas como sílice, alúmina, etc., y la necesidad de introducir las piezas en un autoclavado en túnel. Esta etapa, como ya se ha comentado, es la que impide al nuevo fibrocemento su empleo como material para tuberías.

Pero el problema a partir del cual surge una de las necesidades que se intentan solucionar en esta tesis doctoral, es la no existencia por el momento de un sistema robusto y fiable de control de las propiedades finales del fibrocemento a través de las medidas en línea de alguna variable del proceso, con lo que la calidad del producto final solo puede controlarse en discontinuo midiendo la densidad en tierno, lo cual ofrece unos resultados aceptables, pero susceptibles de mejora.

Se pretende, por tanto, solucionar las necesidades expuestas, empleando para ello métodos de análisis complejos y avanzados, que serán explicados en el capítulo 3.

### **2.1.1.2. Importancia del control**

Un análisis de la fiabilidad de un medidor, de su robustez, de su exactitud y precisión, conlleva amplios estudios sobre el comportamiento del sistema, pero las ventajas que se derivarían de una solución satisfactoria pueden hacer que las empresas del sector vean en esta investigación una interesante inversión que les podría reportar beneficios. De este modo, la industria del fibrocemento y otros materiales compuestos con fibras, en la conferencia IIBCC (*“International Inorganic-Bonded Fiber Composites Conference”*) de 2008, premió este trabajo por ser el más influyente a nivel mundial.

Por tanto, el empleo del sistema de control va mucho más allá de una simple complicación en el proceso de producción, resultando ser una mejora

cualitativa de vital importancia para el desarrollo del sector. Algunos ejemplos son: la posibilidad de fabricación de productos con distintas calidades según la demanda, el alcance en cada calidad de una mayor homogeneidad y la disminución del rechazo de materiales, así como otras muchas ventajas económicas derivadas de una mejor comercialización.

### 2.1.2. Propiedades

De forma resumida, las principales propiedades que presenta un fibrocemento son las siguientes:

- *Resistencia:* El fibrocemento presenta elevadas resistencias mecánica, térmica y química. Resiste la luz del sol, temperaturas extremas, el fuego, vientos fuertes, impactos en el tiempo, etc., así como resiste de forma excelente la deformación, y apenas sufre procesos de pudrimiento o agrietamiento.
- *Capacidad de aislamiento elevada.*
- *Flexibilidad de presentación:* Puede presentarse con gran variedad de formas y diseños (liso, ondulado, pintado, etc.). Con el cambio a celulosa se ha perdido la posibilidad de conformar tuberías.
- *Facilidad para su mecanización:* Se puede cortar, taladrar, pintar, etc.
- *Fiabilidad en sus propiedades.* Este aspecto siempre ha estado presente en el fibrocemento, y con la presente investigación se pretenden establecer las condiciones para que en su producción industrial se pueda obtener un producto con la calidad deseada.

Estas propiedades le confieren unas características que hacen que sea un excelente material de construcción, y son las que han hecho que este producto adquiera un importante nicho de mercado.

Las propiedades medidas habitualmente en planta son: resistencia, densidad y espesor de las placas, a distintos tiempos de la fabricación. En concreto, se miden:

- Índice de clase a las 48 horas, 7 días y 40 días.
- Espesor a las 48 horas, 7 días y 40 días.

- Densidad de la placa en tierno, a los 7 días y a los 40 días.
- Momento flector a los 7 días.

El **índice de clase** es una forma que se tiene de llamar a la fuerza que se debe aplicar por metro de material, para que éste se rompa. Su determinación es una prueba, por tanto, destructiva. Se aplica una fuerza a cada lado de la placa, y se va aumentando progresivamente hasta que ésta se rompe. Sus unidades vienen dadas en N/m. En la figura 2.2 se observa un esquema del ensayo normalizado según la norma europea EN-494.




Figura 2.2 – Esquema del ensayo para la determinación del Índice de Clase.

Se calcula mediante la ecuación (1):

$$F_s = \frac{F}{b} \cdot 10^3 \quad (1)$$

Donde  $F$  es la fuerza aplicada a la placa para rotura (en N),  $b$  el espesor medido en la placa (en m) y  $F_s$  el índice de clase en N/m. Si la distancia entre apoyos ( $d$  representa dicha distancia en mm) es diferente de la especificada en la norma, se aplica otra expresión para el cálculo del índice de clase (2).

$$F_s = \frac{F}{b} \cdot \frac{d}{1100} \cdot 10^3 \quad (2)$$

El **espesor** y la **densidad** indican el grado de compactación de la placa. Su medida se encuentra igualmente normalizada. Cuanto más compacta sea la placa,

más interconectadas están las moléculas entre sí, y cabe esperar unas mejores propiedades mecánicas. Este razonamiento se refiere a una misma composición de entrada, ya que si se incluye la mejora que puede suponer una variación de la densidad debida al empleo en mayor proporción de una materia prima beneficiosa en sus efectos, el resultado se complica, no siendo tan claros los efectos, ya que una placa con menor densidad e igual resistencia mecánica es más apetecible que otra de mayor densidad.

Por último, el **momento flector** indica la deformación que sufre una placa a una distancia dada de la sujeción, al aplicar una fuerza determinada. Se puede entender mejor mediante la figura 2.3. El concepto es el mismo que para el índice de clase, con la salvedad de que el ensayo se realiza en dirección longitudinal a las ondas del producto, en vez de transversal. De hecho, para placas planas, ambos ensayos son idénticos.




Figura 2.3 – Esquema del ensayo para determinación del Momento Flector.

El momento flector inducido por la fuerza aplicada  $F$  (en N), con una distancia entre apoyos  $d$  (en mm), para placas de espesor constante, viene determinado por norma europea por la ecuación (3):

$$M = \frac{F \cdot d}{4 \cdot b} \quad (3)$$

Donde  $b$  es la longitud de la muestra (en mm). Las unidades en las que se mide este momento flector  $M$  son, por tanto, N·m/m.

Para placas de espesor variable, la expresión es ligeramente distinta (ecuación (4):

$$M = \frac{F \cdot d}{6 \cdot b} \quad (4)$$

## 2.2. PROCESO DE FABRICACIÓN DEL PAPEL

La definición de papel según la R.A.E. es, en su primera acepción, la de “hoja delgada hecha con pasta de fibras vegetales obtenidas de trapos, madera, paja, etc., molidas, blanqueadas y desleídas en agua, que se hace secar y endurecer por procedimientos especiales”. El proceso de producción muestra multitud de variantes, y depende del tipo de papel que se desee obtener, así como de las materias primas de las cuales se parte.

Dependiendo del tipo de papel, las aplicaciones son muy variadas. Las más importantes, en cuanto a cantidad de producción, son las siguientes (Aspapel, 2014):

*Papel prensa:* Utilizado para la impresión de diarios, está fabricado mayoritariamente a base de papel recuperado o pasta mecánica. Puede ser blanco o ligeramente coloreado y su gramaje habitual oscila entre 40 y 52 g/m<sup>2</sup>, aunque puede llegar a 65 g/m<sup>2</sup>.

*Papel para impresión y escritura:* Utilizado para revistas, libros, cuadernos, agendas, sobres, folletos, carteles, papeles de oficina..., puede ser estucado o no estucado, dependiendo del uso a que esté destinado. El estucado es un proceso mediante el que se adicionan al papel, por una o por las dos caras, una mezcla de productos con base de caolín o carbonato cálcico, que permiten mejorar las características de impresión, haciendo el papel más brillante, más opaco y más uniforme.

*Papel higiénico y sanitario:* Fabricados a base de fibra virgen o papel recuperado o una mezcla de ambos, se utilizan en la higiene personal (papel higiénico, compresas, pañales, pañuelos...), en el ámbito doméstico (rollos de papel de cocina, servilletas, manteles, filtros de café...) y como material sanitario y de limpieza industrial.

*Papel para envases y embalajes: Papeles para cartón ondulado y cartoncillo.* El papel para cartón se utiliza en las distintas capas de las cajas de cartón ondulado, se fabrican básicamente con papel recuperado, si bien pueden incorporar, en distinta proporción, pasta virgen. El cartoncillo se emplea en la fabricación de estuches plegables o envases, es un material compacto hecho a base de pasta virgen y/o papel recuperado, con varias capas y normalmente acabado con una capa de papel estucado.

*Papeles especiales:* La industria papelera española fabrica una amplísima gama de productos de alta tecnología: papel impermeabilizado para embalaje de productos hortofrutícolas, papel microrrizado de gran extensibilidad, papel moneda, papel metalizado directamente por alto vacío, papel autoadhesivo inhibidor del moho, papel acetato de celulosa transparente, etc.

En función del tipo de papel que se produzca en una fábrica, las variables de operación cambian notablemente y, con ello, la producción. En la presente tesis se profundiza en la fabricación de papel prensa y papel para impresión ligeramente estucado, por ser productos de bajo valor añadido donde una mejora de la calidad puede tener un gran impacto en la competitividad de las empresas.

### **2.2.1. Procesos industriales**

La fabricación de papel consiste en la formación de una hoja mediante un proceso que presenta un flujo de materias relativamente lineal. Se puede observar un ejemplo de la máquina de producción de papel en la figura 3.1.



Figura 3.1 – Ejemplo de una máquina de papel.

En los últimos años se han producido avances significativos en todas las áreas de la producción de papel, desde las materias primas hasta el producto final. El objetivo actual es reducir al máximo los errores o fallos de funcionamiento, para mantener la competitividad de las máquinas.

Las principales etapas de las que se compone la fabricación de papel consisten en:

- Preparación de la pasta: Esta es la sección donde las materias primas se preparan para entrar en las siguientes etapas de producción. Esta sección implica la existencia de numerosos procesos, habitualmente para la eliminación de contaminantes, refinado de las fibras, regulación de la consistencia y almacenamiento.
- La máquina de papel propiamente dicha, que se compone de:
  - La cabeza de máquina, donde se distribuye uniformemente la suspensión que llega de anteriores etapas, formando una lámina.
  - La sección de formación, donde al eliminarse gran parte de la humedad de la lámina formada, se busca que las fibras queden entrelazadas de forma óptima.

- La sección de prensa, donde se continúa eliminando humedad de la hoja mediante prensado.
- La sección de secado que, como el propio nombre indica, continua preparando la hoja de papel por eliminación de humedad.
- La calandria, donde ya se puede observar el espesor que tendrá la hoja y su acabado superficial final.
- La sección de bobinado, donde se obtiene el producto final.

El final de la parte húmeda, conocido habitualmente con el término anglosajón “wet-end”, es la sección donde la suspensión de pasta se distribuye y el agua se elimina de tal forma que la formación de la hoja es óptima. Las etapas consideradas como el final de la parte húmeda son la cabeza de máquina, la sección de formación y la sección de prensado (especialmente la primera parte del prensado, que en algunos casos se conoce como prensado húmedo).

- Finalmente, tras la máquina de papel, queda la etapa de finalización de rollos, donde se preparan éstos para su embalaje y envío al cliente.

El final de la parte húmeda de la máquina de papel presenta un comportamiento complejo, como por ejemplo los diferentes mecanismos de floculación que tienen lugar al añadir el floculante, los cuales resultan cruciales para la retención, drenaje y formación de la hoja. La química en el final de la parte húmeda también resulta compleja, y de momento no se tienen modelos determinísticos aplicables a la generalidad de los procesos.

Normalmente se intenta controlar esta parte del proceso monitorizando las propiedades del producto final, pero este sistema requiere esperar a los resultados de ensayos en laboratorio, y deja abierto un amplio margen para la aparición de productos fuera de especificaciones. Teniendo en cuenta este retraso en las medidas de laboratorio, la naturaleza compleja del sistema y las actuales velocidades de producción, se puede denotar claramente la necesidad del empleo de técnicas avanzadas de análisis de datos, que permitan mejorar las predicciones de propiedades del producto final así como el control del final de la parte húmeda. Existen numerosos estudios aplicando este control predictivo mediante diferentes modelos y optimizando el final de la parte húmeda, como se comprueba en la sección de resultados de la presente tesis.

Los productos de papel y cartón presentan una estructura compleja y contienen componentes muy diferentes. Los requerimientos del producto final dependen en gran manera del tipo de papel producido, y pueden ser muy variados. Por tanto, para optimizar cada tipo de papel es necesario un conocimiento profundo de la fisicoquímica de las materias primas, de la estructura de los productos y de las operaciones unitarias.

### **2.2.1.1. Importancia del control**

En la fabricación de papel cada día existe una mayor competitividad, permitiendo la existencia de muy pocos errores en el proceso de fabricación. Todo ello va unido a mayores demandas, que exigen una mayor velocidad en la fabricación, y a una legislación mucho más estricta desde el punto de vista medioambiental.

Una característica deseable en la fabricación es la presencia de propiedades uniformes o controlables según la calidad del producto que se quiera obtener. En la bibliografía se encuentra que en las investigaciones uno de los puntos más importantes a tener en cuenta es el control de procesos, para poder actuar sobre el sistema de forma eficiente y reducir por tanto los costes de operación.

Dentro del control de la máquina de papel, presenta gran relevancia el control en la parte húmeda. La química de la parte húmeda es, fundamentalmente, química coloidal, que afecta de forma muy significativa a la retención, el drenaje y la formación del papel. Su control es, por tanto, una tarea en continua mejora, debido a la gran importancia que tiene, por obtener una producción estable y de calidad.

¿Qué beneficios presenta entonces un buen control? De forma esquemática, los beneficios son los siguientes:

- Estabilización de parámetros de fabricación.
- Optimización de condiciones de operación.
- Reducción de gastos por errores en fabricación.
- Aumento de calidad del producto final.

### 2.2.2. Propiedades

Dentro de una fábrica de papel se miden multitud de características del producto final, las cuales se encuentran acotadas para cada tipo de producción. Dichas propiedades determinarán la aceptación del producto en el mercado para el uso para el que se fabrica. Por ejemplo, la blancura y el brillo resultan fundamentales a la hora de elegir un papel de oficina. La opacidad ha de ser adecuada a los distintos usos, ya que un papel de calco no puede ser opaco y, por otra parte, un papel para escritura o impresión no puede transparentarse más de un nivel concreto.

Para otros empleos, la resistencia también ha de ser tenida en cuenta. En el papel moneda, el desgaste por ciclos de rozamiento o doblado resulta muy elevado, por tanto, se necesita un papel que con el espesor requerido tenga resistencia suficiente para su empleo. Un papel tisú con baja resistencia no es apto para cumplir sus funciones de forma cómoda para el usuario.

Normalmente se busca cumplir unos requisitos de calidad con el mínimo coste posible, con lo que la optimización de diferentes variables de proceso puede ayudar a cumplir tal objetivo.

Para tener un buen sistema de control es imprescindible tener en el proceso de fabricación los puntos de medida adecuados para intentar controlar todas las situaciones posibles que se puedan llegar a dar en la máquina del papel. Ya se ha comentado que en la parte húmeda es donde se debe ejercer un control más exhaustivo, debido a la gran importancia de la química de esta parte de la fabricación en la calidad final del papel. Por tanto, sería conveniente analizar las medidas a considerar si se quiere tener un control robusto del proceso. Estas medidas, según el caso, constituirán los parámetros de control para la optimización de la fabricación de papel.

Las medidas más útiles en el final de la parte húmeda, a priori, son:

- *pH*. Influye sobre prácticamente todas las reacciones químicas que tienen lugar en la suspensión de pasta, ejerciendo una influencia muy importante sobre la cantidad de sustancias solubles, la estabilidad del  $\text{CaCO}_3$ , el grado de hinchamiento de la celulosa, etc. Las variaciones del pH pueden producir como resultado

desigualdades de calidad en el producto final y depósitos en el proceso.

- *Demanda catiónica.* Parámetro medido habitualmente en las fábricas que sirve a menudo como índice de calidad de las aguas de proceso, y que es función de la basura aniónica del sistema. Una variación en la carga puede indicar un empleo excesivo de químicos (Al, almidón, etc.) o variaciones en la composición de la pasta, por ejemplo.
- *Temperatura.* Influye sobre las reacciones químicas, el drenaje y la formación de depósitos, entre otras cosas. Es conveniente evitar choques térmicos en el proceso, y mantener la temperatura constante en el proceso y en el tiempo.
- *Conductividad.* Depende de la concentración y la naturaleza de los iones libres presentes en la suspensión de pulpa. Puede variar con la dureza del agua, y se emplea como medida indirecta de la concentración de sales disueltas.
- *Concentración de Ca y Al.* Elevadas concentraciones de iones como el  $\text{Ca}^{2+}$  o el  $\text{Al}^{3+}$  llevan a la creación de depósitos y, como consecuencia de ello, se reducen las propiedades de resistencia. Para su control es necesario tener en cuenta la dureza del agua empleada en el proceso, y evitar un exceso de compuestos con Al y la presencia de  $\text{CaCO}_3$  en pH ácidos.
- *Contenido en gas.* Los efectos de un valor elevado del mismo son: la formación de espumas en superficies abiertas, que tienen como consecuencia la flotación de stickies, reducción del drenaje, reducción de la eficacia de bombeo, incremento de la actividad microbiológica, variaciones de presión y flujo y una reducción de la calidad del producto final (resistencia menor y suciedad en el producto).
- *Sustancias orgánicas.* Se pueden medir caracterizando diferentes compuestos, mediante técnicas como la cromatografía de gases, o con medidas más sencillas, no específicas, como la demanda química de oxígeno (DQO) o los compuestos orgánicos totales (COT). Otra medida de interés es la del almidón presente, para evaluar su adsorción.
- *Retención.* Unos valores adecuados de la retención de fibras, finos y cargas minerales, llevan a una buena calidad de las aguas blancas (para su posterior mezclado con la pasta en la caja de

alimentación), un drenaje más rápido, ahorro de fibras y cargas y una distribución de tamaños de partícula óptima, entre otras ventajas.

### *Medidas en línea para el control de la fabricación de papel*

Las tendencias actuales indican una clara predisposición a tener medidas en línea, debido a la capacidad de crear sistemas inmediatos de control a partir de éstas. A continuación se enumeran las más extendidas actualmente:

- pH.
- Consistencia.
- Demanda catiónica.
- Conductividad.
- Cenizas.
- Determinados aniones y cationes.
- Temperatura.
- DQO y COT.
- Almidón.
- Contenido en aire.
- Presión.
- Flujo.
- Temperatura.
- Grado de refino.
- Longitud de fibra.

Con todas estas medidas, la tarea consiste en elegir las más adecuadas, según el parámetro que se desee optimizar. En esta elección los métodos matemáticos adquieren gran importancia, especialmente aquellos basados en el conocimiento del proceso.

La experiencia es otro factor a tener en cuenta en la elección de las medidas más adecuadas, ya que el basar todos los cálculos en las matemáticas puede conducir a resultados poco fiables.

### **3. HERRAMIENTAS DE MODELADO MATEMATICO**

En sistemas como la fabricación de fibrocemento y la parte húmeda en la fabricación de papel, donde el comportamiento es difícilmente observable mediante representaciones simples de cualquiera de las medidas respecto a las propiedades a determinar, el método empleado puede determinar el éxito de la investigación.

Para la creación de modelos matemáticos que permitan la predicción de distintas propiedades finales de los productos, así como de condiciones de operación, se presentan las siguientes herramientas:

#### **Técnicas clásicas**

Esta opción incluye el análisis y modelado mediante la búsqueda de regresiones simples, múltiples, ya sean lineales o no lineales, o bien la utilización de diseño de experimentos u otros métodos estadísticos clásicos. La bibliografía sobre este tipo de análisis es muy amplia y recoge las claves a tener en cuenta para una óptima elaboración de modelos (Box G. y col., 1978; Cánavos G.C., 1992; Himmelblau D., 1969; Speigel M., 1991).

El estudio de estos métodos se encuentra muy desarrollado, y son de continua aplicación en trabajos de investigación. Cabe destacar el empleo del diseño experimental para analizar las respuestas de un sistema por optimizar con un mínimo error, lo que resulta una herramienta útil cuando se quieren evaluar las respuestas de un sistema dado (una sección de proceso, experimento de laboratorio o modelo matemático complejo) en un entorno multidimensional, y ofrece una primera aproximación del efecto de cada variable de entrada al sistema sobre cada una de las salidas del mismo.

Este tipo de modelos es comúnmente empleado en problemas del día a día en laboratorio o en fábrica. Proporcionan respuestas rápidas a problemas concretos, siendo de gran utilidad como una primera aproximación, e incluso en ocasiones dando una respuesta suficiente a las necesidades planteadas.

#### **Modelos físico-químicos determinísticos**

Suponen el extremo opuesto a los anteriores en cuanto al tiempo de desarrollo y aplicaciones. El desarrollo de modelos físico-químicos como, por

ejemplo, la cinética de un proceso, o su físico-química, requiere la existencia o investigación de un conocimiento vasto sobre el sistema estudiado, que permita asemejarlo a un tipo concreto de representación matemática, que indique un comportamiento generalizable a todos los procesos del mismo estilo.

El tiempo necesario para realizar este tipo de estudios suele ser elevado, si bien se obtiene a cambio no solo un modelo basado en fenómenos generalizables a cualquier sistema parecido, sino una validez que va más allá de posibles cambios en las líneas de fabricación.

La solución de problemas a largo plazo es conveniente encaminarla con este tipo de herramientas si se quiere asegurar una solución óptima.

#### **Tratamiento avanzado de datos**

Cuando no se poseen los conocimientos suficientes para abordar un modelado físico-químico, existen técnicas alternativas que no poseen la misma capacidad de generalización, pero presentan la habilidad de poderse desarrollar a corto-medio plazo sin necesidad de un conocimiento exhaustivo de los comportamientos implícitos en el sistema estudiado.

Lo que sí resulta necesario es un conocimiento amplio tanto de la sección o secciones implicadas en los modelos a crear, así como de la frecuencia, validez y significado de las medidas existentes.

Este tipo de herramientas se ha empleado en la presente tesis debido a las siguientes razones:

- Los sistemas a estudiar son complejos: presentan mecanismos de floculación en presencia de mezclas multicomponente, y simultáneamente tienen lugar reacciones de gran complejidad, en un caso el fraguado del cemento y, en el otro, las interacciones entre diferentes aditivos químicos.
- Dichos mecanismos físico-químicos no han sido estudiados desde el punto de vista determinístico debido a su ya citada complejidad.
- Se ha observado en trabajos previos que la físico-química presente donde tiene lugar la floculación influye notablemente sobre diferentes propiedades de los productos finales. Por tanto existe

una necesidad en la industria de controlar estos procesos a corto-medio plazo.

Actualmente suele presentarse un entorno con multitud de variables en la fase de adquisición de datos, por lo que se proponen técnicas estadísticas algo más avanzadas para su tratamiento, y la determinación de aquellos datos realmente necesarios y fiables para la construcción de modelos matemáticos. El análisis de componentes principales, los mínimos cuadrados parciales y la creación de matrices de correlaciones, correlaciones cruzadas con el tiempo e histogramas divididos en efecto de variables discretas, entre otras muchas técnicas, resultan de gran interés en el análisis de grandes bases de datos multivariable, y serán empleadas en la presente tesis doctoral, principalmente en la industria del papel, donde se ha dispuesto de gran cantidad de información de planta.

De nuevo la bibliografía resulta pródiga en este material, como se verá en el siguiente apartado. Una explicación teórica detallada de estos métodos no aportaría gran novedad en el estado del arte, con lo que en esta tesis se estudian los pormenores de las redes neuronales, cuyo empleo, en el caso de la industria del fibrocemento es innovador y supone un importante avance con respecto al estado actual del arte. Estas herramientas sí se han empleado con profusión en la industria del papel, con diferentes objetivos que serán explicados en el apartado de antecedentes. En el caso de esta industria su empleo corrobora su utilidad en sistemas de comportamiento complejo. Además en esta tesis se comparan sus cualidades con las de métodos estadísticos clásicos y con métodos de análisis multivariable. El aspecto innovador en este caso es el modelado de la parte húmeda de la máquina de papel utilizando un sensor de floculación.

A continuación se describen los métodos más empleados de tratamiento avanzado de datos.

## **3.1. PRINCIPALES MÉTODOS DE TRATAMIENTO AVANZADO DE DATOS**

### **3.1.1. Métodos de análisis multivariable**

Existen diferentes técnicas de análisis multivariable, conocidas con las siglas MVA del anglosajón “MultiVariate Análisis” (Martens H. y Naes T., 1998; Matlab 6.5, 2002). El análisis multivariable permite manejar grandes cantidades de

datos, y los resultados que mediante técnicas clásicas no resultaban explícitos ayudan a la mejora de los procesos industriales. Las diferentes técnicas multivariable se pueden clasificar en tres grupos:

- Análisis de grupos, que clasifica los datos en diferentes grupos según sus valores. Cada grupo representa datos de naturaleza similar.
- Técnicas de reducción dimensional, como por ejemplo el análisis de factores comunes de máxima probabilidad (En anglosajón: Maximum Likelihood Common Factor Analysis “MLCFA”) y el análisis de componentes principales o PCA (del anglosajón “Principal Component Análisis”).
- Otros métodos multivariable, entre los que se incluyen el análisis de varianza multivariable, el análisis de correlación canónica, los mínimos cuadrados parciales, etc.

Existe una gran variedad de aplicaciones de estas técnicas. Por lo general, la calibración multivariable para el desarrollo de sensores virtuales con buena capacidad de predicción es la aplicación más común (Antti H. et al., 2000; Harrison R.P. y col., 2004; Sparén A. y col., 2003; Wold S. y Kettaneh-Wold N., 2003). La calibración multivariable combinada con la espectroscopía de reflexión de infrarrojo cercano (NIR) ha probado ser una herramienta eficiente para la determinación de faltas de uniformidad en pastas kraft (Antti H. y col., 2000). La reducción del índice kappa en pastas puede ser también predicha con éxito (Sparén A. y col., 2003). La predicción de la DQO en los efluentes provenientes del blanqueo se ha realizado con un error aproximado de 60 unidades de DQO.

Algunas herramientas multivariable como los mínimos cuadrados parciales o el análisis de componentes principales han sido empleados con datos de operación del refino de una fábrica de papel prensa a partir de pasta termomecánica (Harrison R.P. y col., 2004). Mediante este estudio, se seleccionaron las variables de proceso que más influencia presentaban sobre la relación entre la cantidad de producto fabricada y la cantidad de materias primas necesarias. También se obtuvieron recomendaciones sobre el empleo de los datos disponibles y la ponderación de las entradas del modelo.

El análisis regresivo multivariable se ha empleado con éxito para la localización del origen de fluctuaciones en procesos industriales continuos (Saarela O., 2002). El beneficio del empleo de esta herramienta depende de la naturaleza de cada proceso. Si las fluctuaciones se presentan con frecuencia, el poder

encontrarlas sin emplear para ello gran cantidad de tiempo podría tener un importante beneficio económico.

Otros resultados, mostrados más específicamente, son la validación del empleo de la fluorescencia como herramienta analítica para el análisis de procesos y la optimización en la industria pasteropapelera (Billa E. y col., 2000), y la reducción del tiempo de reacción en un 4.3% en un reactor industrial discontinuo por cargas (Zheng L.L. y col., 2001).

Las técnicas de análisis multivariable han sido también empleadas en combinación con las redes neuronales (Miyanishi T. y Shimada H., 1998). Se pueden también emplear para el control avanzado en la fabricación de papel y cartón. Las propiedades de este grupo de técnicas fueron descritas, entre otros, por Wang H. y col. en 1997.

#### **3.1.2. Métodos “Data Mining”**

Existe un conjunto de técnicas que surgieron para emplearse como rastreadores de datos erróneos o incompletos en una base de datos. Por el tipo de tarea que debían procesar, fueron llamados con el término anglosajón “Data Mining” o su traducción, minería de datos). Dentro de éstos se encuentran los algoritmos genéticos, árboles de decisión, bases de datos multidimensionales, redes neuronales, etc. (Back, A. et. al., 2001; Presser, C.C., 2001; Ullman, J.D., 2002).

De los diferentes métodos de minería de datos, tanto las redes neuronales como los algoritmos genéticos han sido ampliamente empleados en solitario o combinados en la industria del papel. Sin embargo, no se han encontrado ejemplos previos de su aplicación en la industria del fibrocemento, debido a la novedad de su aplicación.

Por la extensión del empleo en la bibliografía consultada y la idoneidad de los sistemas a estudiar, como se verá posteriormente, se han elegido las redes neuronales como sistemas de modelado en la presente tesis doctoral. Por la extensión de sus aplicaciones y la breve explicación incluida sobre su funcionamiento, se ha decidido otorgarles un capítulo propio.

### 3.1.3. Redes neuronales

A modo de resumen, se exponen las principales razones por las cuales se ha seleccionado este tipo de técnicas para realizar la fase de modelado en la presente tesis.

- Su extensión en el tipo de aplicaciones descritas para la fabricación de papel, así como la novedad de su aplicación en la industria del fibrocemento.
- El éxito de experiencias previas en su manejo como en la elaboración del proyecto final de carrera y el diploma de estudios avanzados del doctorando.
- La capacidad de modelado de sistemas complejos y generalización de patrones.
- La posibilidad de crear modelos estáticos sustituibles periódicamente, como etapa previa a la elaboración de un sistema automático de predicción basado en estos modelos y en técnicas de validación dinámica.
- La disponibilidad de entornos de programación de potencia contrastada (Matlab) para el desarrollo de estos modelos y la automatización de los procesos en los que puedan tener influencia.

No obstante, en su empleo conviene no olvidar la necesidad de crear otros modelos para aquellas condiciones de operación distintas a las disponibles en los datos de entrenamiento de los modelos, ya que son modelos válidos dentro del entorno estudiado, con dudosas capacidades de extrapolación.

Una red neuronal se puede definir como una herramienta matemática para el análisis de datos, cuya actuación consiste en aprender patrones de comportamiento complejo de cualquier tipo de procesos, mediante la reducción del error cometido por la red en la predicción de aquello que se desea, optimizando para ello numerosos parámetros que constituyen su arquitectura y método de trabajo.

Dicha herramienta consiste en un determinado número de nodos matemáticos (neuronas artificiales o perceptrones), en los cuales se reciben unas entradas que se suman para, aplicando posteriormente ecuaciones de transferencia

adecuadas, dar una salida que se pueda propagar como señal dentro del modelo. Estas operaciones son sencillas y no requieren de elevados conocimientos matemáticos para su entendimiento. La potencia de las redes neuronales reside en que los nodos individuales se encuentran en diferentes capas, formando redes altamente interconectadas, con una arquitectura inspirada en la corteza cerebral, que permiten el aprendizaje de patrones no lineales de comportamiento (Tsoukalas, L.H. y Uhrig, R.E., 1997).

Tanto la estructura como el funcionamiento de una red pueden variar, dando así lugar a diferentes tipos de redes neuronales.

#### **3.1.3.1. Tipos de redes**

Los diferentes tipos de redes neuronales se pueden emplear según el tipo de sistema que se estudie y el tipo de datos que se analice. Los nodos neuronales, como ya se ha comentado, se distribuyen en capas, entre las cuales se establecen conexiones nodo a nodo con unos pesos característicos (figura 3.2). Según las conexiones sean solamente de una capa inferior a otra capa superior, o haya conexiones entre neuronas de una misma capa, incluso conexiones hacia capas anteriores (las conexiones trabajan en un único sentido), se tienen diversos tipos de redes.

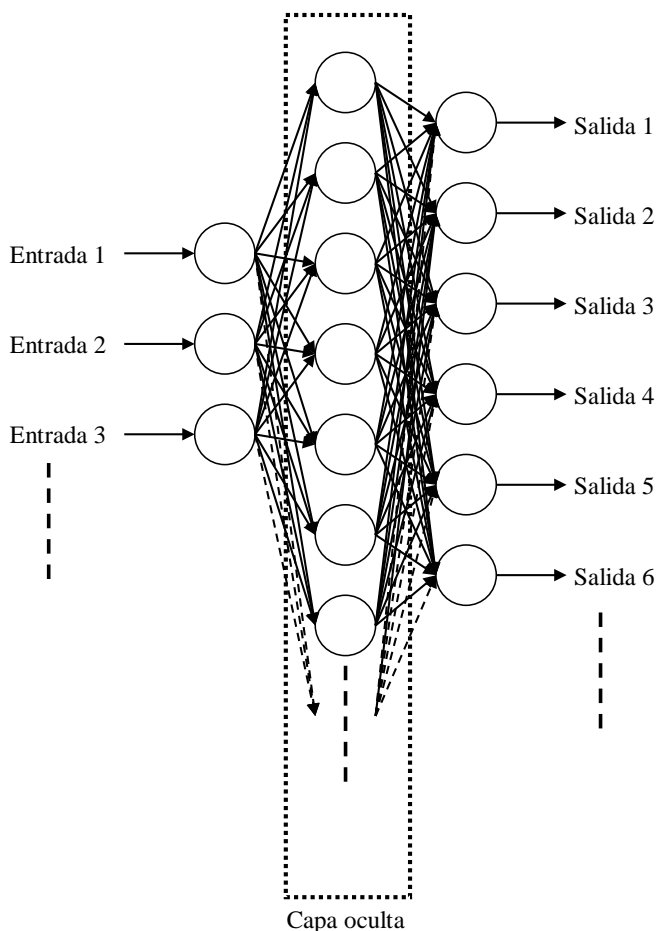


Figura 3.2 - Red neuronal sencilla, del tipo “alimentación hacia adelante”.

Los tipos de conexiones entre los nodos de las distintas capas de la red neuronal indicarán el tipo y la aplicación de la misma. En la figura 3.2 se muestra el caso más habitual de red conocida con el nombre de red de alimentación hacia adelante, correspondiente al más comúnmente conocido término anglosajón “feedforward”, donde las conexiones sólo se establecen entre una capa y la siguiente. Esta red, también conocida como perceptrón multicapa, se puede esquematizar según la figura 3.3, donde “ $W$ ” es la matriz de pesos de cada capa, con su vector de factores de corrección “ $b$ ”, el vector “ $n$ ” de entrada a cada nodo, y el de salida “ $a$ ”. Los superíndices indican la capa. Despejando todos los cálculos se obtiene la ecuación mostrada bajo el esquema. Cada nodo neuronal aplica a la suma de las entradas que recibe una función de transferencia que modifica la señal

para obtener una salida concreta. Las funciones utilizadas varían según el sistema a estudiar, y pueden consistir en funciones escalón, lineal, hiperbólica tangencial, logística, variaciones de éstas o cualquier otra definida a efectos de cálculo y convergencia.

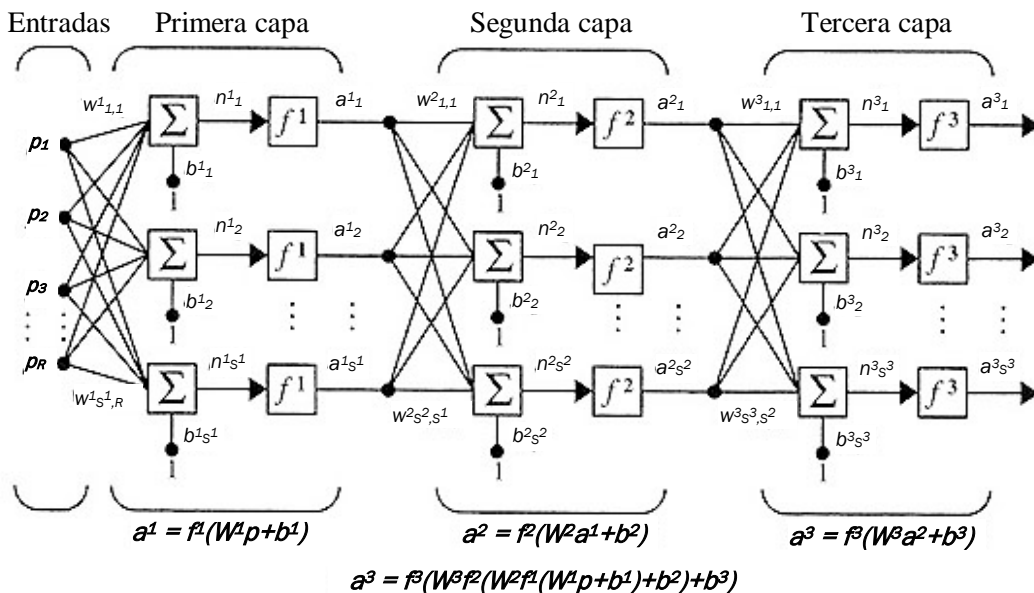


Figura 3.3 – Esquema de un perceptrón multicapa de 3 capas. Fuente: Hagan y col., 1995.

El empleo de una función de transferencia u otra en cada uno de los perceptrones es justificable siguiendo un criterio de optimización tanto del error cuadrático medio cometido en el entrenamiento de la red (que no es otra cosa que la búsqueda de pesos óptimos en las matrices de pesos que hagan que el error de predicción de la red respecto a los datos reales utilizados sea el mínimo posible), como del número de iteraciones necesarias para llegar a valores concretos de dicho error.

Dicho procedimiento resulta igualmente aplicable a la hora de optimizar la arquitectura de la red, es decir, el número de capas ocultas y número de neuronas por capa oculta. Por tanto, en la fase de búsqueda de una red óptima, se puede emplear tanto el método de prueba-error, aplicable mediante la creación de distintas redes con valores diferentes de los parámetros, como la creación de diseños experimentales. Estos métodos de optimización resultan los más

adecuados para la optimización de la mayoría de los parámetros, para la obtención de una red neuronal lo más robusta posible.

El tamaño de la red puede variar enormemente, y es la experiencia y el propio sistema estudiado el que marca qué tamaño es el óptimo en cuanto a requerimientos de cálculo y resultados obtenidos. Este tamaño variará según la calidad y cantidad de datos recogidos, con lo que debe considerarse como un análisis dinámico, en constante optimización. Es importante evitar un sobredimensionado, que repercuta en mayores tiempos de entrenamiento de la red neuronal y en una limitación de su capacidad para generalizar comportamientos.

En la bibliografía se encuentran, principalmente, dos clasificaciones. En la primera de ellas, las redes se clasifican en función de los datos que procesan:

- *Redes autoasociativas*: Los datos de salida son los mismos que los de entrada. Se emplean en sistemas de filtrado de señales y depuración de bases de datos.
- *Redes heteroasociativas*: La salida es distinta a la entrada. Se emplea para cualquier tipo de sistema de entrada-salida que se desee estudiar (en el caso de la presente tesis, las redes usadas serán de este tipo).

La segunda clasificación de las redes neuronales atiende a los tipos concretos de redes, con sus nombres correspondientes y características concretas. A este respecto los siguientes ejemplos de redes neuronales son los más empleados en distintos campos del saber:

- *Redes basadas en el aprendizaje de Widrow-Hoff*: Redes de aplicaciones principalmente destinadas a sistemas lineales, como la red ADALINE. Utilizan algoritmos de minimización del error cuadrático medio y sus aplicaciones más famosas resultan de la eliminación del eco de señales acústicas.
- *Perceptrones multicapa*: Son las redes más empleadas para el aprendizaje de sistemas no lineales. Consisten en la aplicación en varias capas de los perceptrones. Para el entrenamiento emplean los algoritmos de retropropagación, en sus diferentes variantes, tanto el algoritmo clásico como sus modificaciones heurísticas y numéricas de cálculo.
- *Redes asociativas*: Redes neuronales que incluyen en el cálculo expresiones lógicas, como la red asociativa simple, o la red de

reconocimiento. Emplean otras reglas como la de Hebb (Hebb D.O., 1949) para la reducción del error de entrenamiento. Su aplicación suele residir en la distinción de clases o grupos.

- *Redes competitivas*: Trabajan con un sistema diferente, basado en la comparación competitiva de diferentes valores llamados prototipos en una capa recurrente. Este tipo de redes son más parecidas a los algoritmos genéticos, y emplean solo aquellos prototipos que proporcionan una mejor respuesta. Dentro de este tipo de redes se encuentran los mapas autoorganizados, conocidos por su término anglosajón “Self Organising Maps”, o redes de Kohonen (Kohonen T., 1987), muy empleados para numerosas aplicaciones.
- *Red de Grossberg*: este tipo de red neuronal se basa en el concepto del rellenado de datos incompletos, tal y como lo realiza nuestro cerebro con las imperfecciones de la vista, por ejemplo.
- *Otros tipos de redes neuronales*: existen otros muchos tipos de redes y modificaciones de los ya descritos. Redes neuronales probabilísticas, de base radial, de regresión general, con tiempos muertos (Redes de Elman, de media móvil no lineal autorregresiva, recurrentes en tiempo real, polinómicas), etc. (Elman J.L., 1990)

Se puede decir, por tanto, que estos sistemas de cálculo se encuentran desarrollados en muy diversas formas y aplicaciones, y que una correcta elección del tipo de red resultará fundamental para la obtención de resultados óptimos. En esta tesis se emplean redes del tipo perceptrón multicapa con algoritmo de retropropagación modificado heurísticamente o con técnicas numéricas de optimización, como el de Levenberg-Marquardt. Este tipo de red se ha elegido como resultado del análisis de la aplicación deseada y de la comparación bibliográfica del empleo de este tipo de redes, y el algoritmo de ajuste de pesos del modelo se ha escogido después de realizar un primer periodo de prueba-error con diferentes algoritmos de entrenamiento, cuyos resultados se muestran en el apartado 6 de resultados.

#### **3.1.3.2. Funcionamiento**

Como se ha comentado anteriormente, la arquitectura de una red neuronal suele ser de capas de nodos neuronales interconectadas según la figura 3.2. Cada

capa tiene su cometido, y el número total de capas determinará la capacidad de la red para prever comportamientos complejos. Por otra parte, a un mayor número de capas ocultas, resultará más complicado evaluar las respuestas de la red a través de sus pesos internos. La capa de entrada presenta los datos a la red neuronal y no presenta la etapa de suma de contribuciones, ya que solo le aplica a las entradas la ecuación de transferencia que se considere más oportuna.

Mediante diferentes tipos de algoritmos, se establece una matriz de pesos de las conexiones, por la cual se establece la importancia de cada conexión en el cálculo que realiza la red. Este cálculo se extiende a través de la/s capa/s oculta/s o intermedia/s de la red, y concluye con una salida en la última capa. En el siguiente apartado se expone con detalle el algoritmo más extendido para las redes neuronales en la industria del papel: el algoritmo de retropropagación.

La reducción de los errores de predicción de una red neuronal tiene lugar mediante un proceso de entrenamiento-aprendizaje, el cual consiste en variar los pesos asignados a cada conexión entre nodos neuronales, de forma que el resultado final sea lo más fiel posible a los datos empleados para el entrenamiento. Existen numerosos algoritmos de retropropagación para dicha variación de pesos, el que se ha empleado es el que se considera más completo para la optimización de la red, según pruebas realizadas al comienzo de la investigación (algoritmo de gradiente descendente, con momento constante y relación de aprendizaje variable).

#### **3.1.4. Algoritmos de retropropagación “Backpropagation”**

El 90% de los trabajos revisados emplean redes con arquitectura de alimentación hacia delante y algoritmos de retropropagación. El algoritmo de gradiente descendente es el más empleado, mientras que de todos los trabajos que emplean los perceptrones multicapa, solo una pequeña minoría cita el empleo del algoritmo de Levenberg-Marquardt, que será útil en la presente tesis como alternativa de resultados parecidos al algoritmo de gradiente descendente, requiriendo menor tiempo de cálculo, en caso de ser necesario para su implantación en fábrica.

Cuando los trabajos que emplean algoritmos de retropropagación especifican el número de capas ocultas empleadas, se observa que la mayoría de ellos (un 56%) emplean redes de una capa oculta, mientras que el empleo de redes

de dos capas ocultas es algo menos común (un 31%), y el de otro tipo de redes con más capas, algo excepcional. La experiencia adquirida (ver anexo V) muestra que, con una correcta optimización de los parámetros de la red neuronal, en la mayoría de las ocasiones es suficiente con una capa oculta, reduciendo tiempo de cálculo sin afectar a la calidad de los resultados, por lo que, salvo en casos específicos obtenidos al comienzo de la investigación, se han empleado redes de una capa oculta en la presente tesis.

La elección del tipo de algoritmo de entrenamiento, o adaptación de los pesos de las conexiones internas, está influido en gran medida por la elección del tipo de red, ya que técnicas como las reglas de aprendizaje de Hebb (Hebb D.O., 1949) o la autoorganización de patrones-prototipo propuesta por Kohonen (Kohonen T., 1987) se emplean con otros sistemas como las redes competitivas o mapas autoorganizados que suponen, en algunos casos, entrenamientos no supervisados.

El algoritmo de entrenamiento de la red elegido en esta tesis doctoral, debido a su extensa aplicación, según la bibliografía, es del tipo de retropropagación, muy ligado a las redes de alimentación hacia delante, conocido en la bibliografía con el término anglosajón “backpropagation”, que se ha aplicado en industrias como la papelera, por ejemplo, en el trabajo de Miyanishi, T. y Shimada, H. en 1998, así como en la gran mayoría de publicaciones con redes neuronales, según se puede comprobar en la sección 4.1 de aplicaciones de las redes neuronales. Estos algoritmos se aplican a redes con un mínimo de tres capas de perceptrones o neuronas (capas de entrada, oculta y de salida).

Los algoritmos de retropropagación se componen de las siguientes etapas en el empleo de la red:

1. Crear unas matrices iniciales de pesos mediante sistemas aleatorios que generan valores entre 0 y 1, positivos o negativos. Este paso se debe a que para un mejor funcionamiento de la red, no es bueno comenzar con pesos iguales, lo cual retardaría la optimización. A veces la aproximación inicial no tiene un gran éxito, y se procede a una nueva inicialización de las matrices de pesos, para la obtención de un sistema lo más cercano posible a las respuestas reales, y que prediga aquello que se desea con fiabilidad.

2. Seleccionar un par o patrón de entrenamiento. Se entiende por patrón de entrenamiento una pareja de datos de entrada a la red y salida deseada. Se irán seleccionando posteriormente todos los datos de los que se disponga.
3. Se suele trabajar con datos en forma de vectores, por lo que si hay "n" entradas se tendrá un vector de "n" elementos como dato de entrada a la red.
4. Con los pesos obtenidos en pasos anteriores, se calculan las salidas que proporcionaría la red actual, sumando en cada nodo todas las entradas que recibe, indicadas por las matrices de pesos, y se les aplica la ecuación que se le asigna a cada capa de neuronas (se hablará más adelante de las ecuaciones empleadas), para obtener una salida, que con la matriz de pesos correspondientes a las relaciones entre la capa actual y la siguiente, permite saber el valor de cada conexión entre las capas. El proceso concluye con la obtención de las salidas de la última capa, que son las respuestas de la red.
5. Se compara el resultado obtenido con el esperable según los datos. Se calcula el error, entendido como la diferencia entre la salida de la red y la respuesta esperada.
6. Aplicando una serie de ecuaciones matemáticas (algoritmo de aprendizaje), se ajustan los pesos de las matrices de la red para minimizar este error. Este proceso se explica con más detalle a continuación.
7. Se repiten los pasos 2-6 para cada par de datos de entrada-salida hasta que el error observado se considera el óptimo, aceptablemente pequeño.

Se tienen por tanto en el entrenamiento de la red dos pasos principalmente. En el primero, que es hacia delante, las señales se propagan de la entrada a la salida de la red para obtener las respuestas. En el segundo, a partir del error cometido, las señales se propagan hacia detrás a través de la red, cuando se ajustan los pesos de la red. Los cálculos se realizan capa a capa, la salida de una capa constituye las entradas de la siguiente, aplicando la matriz de pesos. El cálculo de los pesos se realiza en dirección contraria, intentando alcanzar los valores de consigna.

La principal dificultad de estos algoritmos es que en el proceso de ajuste de pesos, las capas intermedias carecen de valores de consigna, con lo que se pueden dar situaciones en las que se traslada un error acumulado por la red que es difícil de reducir. En ese sentido es siempre aconsejable simplificar al máximo la estructura de los modelos que se vayan a crear, y sólo atreverse con estructuras más complejas si se dispone de potencia suficiente como para aplicar árboles de decisión, algoritmos genéticos u otros sistemas de selección de los mejores modelos, normalmente no aplicables debido al tiempo de cálculo que requieren.

Para un mejor entendimiento de los algoritmos de aprendizaje empleados, se presentan las ecuaciones empleadas en ellos paso a paso.

La entrada a un nodo neuronal viene marcada por la suma de todas las entradas de los nodos de la capa anterior (Ecuación 5).

$$I = x_1 w_1 + x_2 w_2 + \dots + x_n w_n = \sum_{i=1}^n x_i w_i \quad (5)$$

“ $w_i$ ” representa los pesos aplicados a “ $x_i$ ”, que son las salidas de las neuronas de la capa anterior.

Dentro del nodo neuronal, a esta entrada, se le aplica una función, llamada función de activación, que puede ser distinta según el sistema que se trate. Como ya se ha indicado, puede tratarse de una función escalón, sigmoideal logística, hiperbólica tangencial, lineal o de otro tipo, aunque generalmente se aplican las descritas anteriormente.

Se han probado varias funciones en los ensayos previos realizados, pero la combinación de la función logística (Ecuación 6), con factor  $\alpha$  modificado en las capas ocultas, y la función lineal en la capa de salida, es la que ha proporcionado mejores resultados.

$$\Phi(I) = \frac{1}{1 + e^{-\alpha \cdot I}} \quad (6)$$

Con esta función se obtiene la salida de la neurona, que se propagará a la siguiente capa aplicando los pesos correspondientes, en un proceso similar al descrito. La ecuación simplemente da una salida para una entrada, según la función que se estudie.

El cálculo para retocar los pesos y bajar el error es restarle al valor de consigna la respuesta de la red en cada una de las variables. Se obtienen los errores correspondientes. Se eleva al cuadrado el error calculado.

Una vez obtenido el error se aplica la regla Delta, que indica que el cambio en un peso es proporcional a la relación entre el cambio del error al cuadrado y la variación del correspondiente peso, según la ecuación 7, donde  $\eta_{p,q}$  es una constante de proporcionalidad llamada relación de entrenamiento. Los subíndices se refieren a dos nodos neuronales, "p" y "q", situados respectivamente en las capas "j" y "k", siendo "k" la capa que va después de la capa "j" en la red. El peso (w) se considera entre dos nodos neuronales, de ahí los subíndices empleados.

$$\Delta w_{pq,k} = -\eta_{p,q} \frac{\delta \varepsilon_q^2}{\delta w_{pq,k}} \quad (7)$$

Mediante un desarrollo matemático posterior (Tsoukalas, L.H. y Uhrig, R.E., 1997), evaluando la derivada expuesta en la ecuación, se llega a la expresión que indica los nuevos pesos a aplicar en la matriz de pesos correspondientes a la última capa (Ecuación 8), siendo  $\delta_{pq,k}$  un término de error definido según la ecuación 9.

$$\Delta w_{pq,k} = -\eta_{p,q} \frac{\delta \varepsilon_q^2}{\delta w_{pq,k}} = -\eta_{p,q} \cdot \delta_{pq,k} \Phi_{p,j} \quad (8)$$

$$w_{pq,k}(N+1) = w_{pq,k}(N) - \eta_{p,q} \cdot \delta_{pq,k} \Phi_{p,j}$$

$$\delta_{pq,k} \equiv 2\alpha [T_q - \Phi_{q,k}] \Phi_{q,k} [1 - \Phi_{q,k}] = 2\varepsilon_q \frac{\delta\Phi_{q,k}}{\delta I_{q,k}} \quad (9)$$

$\alpha$  es el parámetro de la ecuación logística que se variará en estudios posteriores,  $\Phi_{q,k}$  la salida dada por la neurona “q” de la capa “k”, e  $I_{q,k}$  la entrada a dicha neurona, resultado de sumar las entradas procedentes de la anterior capa, con sus pesos correspondientes.  $T_q$  es el valor real de la salida del par de datos analizado, con el cual se compara la respuesta de la red.

Se han calculado los pesos a aplicar antes de la capa de salida. El proceso para determinar el resto de pesos es algo más complejo, pero con la misma base matemática. Tras cálculos similares a los realizados para la última capa, se llega a la ecuación 10.

$$w_{hp,j}(N+1) = w_{hp,j}(N) - \eta_{h,p} \cdot x_h \sum_{q=1}^r \delta_{hp,j} \quad (10)$$

Donde “ $x_h$ ” son las entradas de capa “i”, anterior a la “j” y dos capas antes de la capa “k” y “r” el número de nodos de la capa “k”. La neurona considerada para el cálculo de los nuevos pesos en la capa “i” se llamaría nodo “h”.

Un esquema representativo con la estructura y nomenclatura de la red se muestra en la figura 3.4. En este esquema, a la capa i-ésima le corresponde el índice “h”, con valores de 1 a “m” (nodos que contiene la capa), a la j-ésima le corresponde el índice “p”, con valores de 1 a “n”, y a la capa k-ésima el índice “q”, con valores de 1 a “r”.

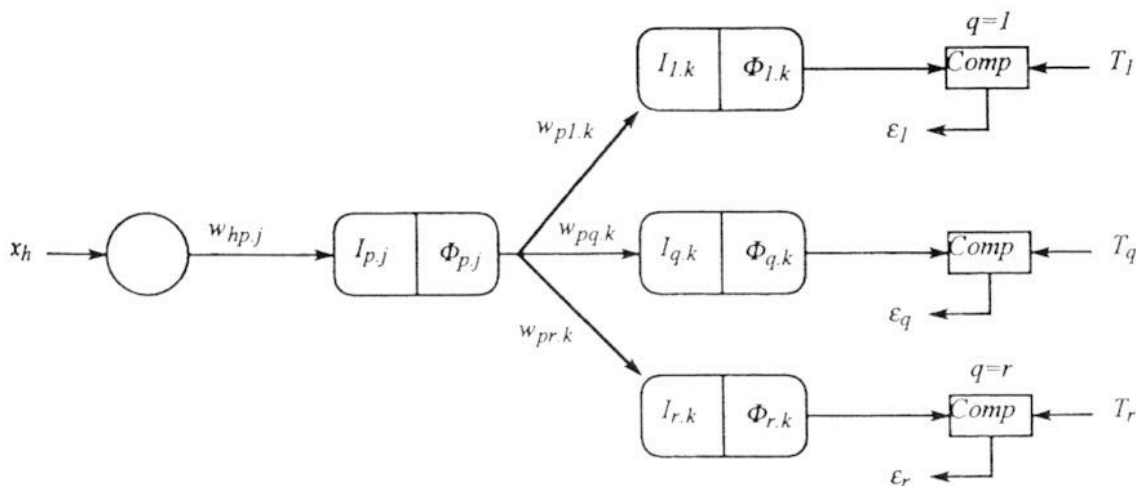


Figura 3.4 - Esquema de una red neuronal empleando el algoritmo de retropropagación (Tsoukalas, L.H. y Uhrig, R.E., 1997).

Aplicando repetidamente la secuencia de cálculo se van reduciendo los errores paulatinamente. El error que se reduce en la red es el de la predicción de los puntos de entrenamiento. Como se verá posteriormente, que este error sea mínimo no garantiza que las predicciones sean mejores, debiendo por tanto optimizarse el entrenamiento-aprendizaje en la red, que es como se le llama a la reducción de los errores.

### 3.1.5. Parámetros especiales de los algoritmos empleados

En alguno de los algoritmos empleados se aplican conceptos más especializados de las redes neuronales, tales como el momento, el ajuste de la relación de aprendizaje y la constante  $\alpha$  de la ecuación logística.

El momento tiene un significado análogo a lo que representa la inercia en física. Quiere decirse con esto que el factor de momento aplicado en los programas realizados en esta tesis doctoral hace que se le dé mayor o menor importancia a los pesos obtenidos en pasos anteriores.

En la ecuación 11 puede verse la influencia del momento ( $\mu$ ) sobre los pesos en el paso inmediatamente anterior al actual.

$$\Delta w_{pq,k}(N+1) = -\eta_{p,q} \cdot \delta_{pq,k} \Phi_{p,j} + \mu \cdot \Delta w_{pq,k}(N) \quad (11)$$

El valor de  $\mu$  puede oscilar entre 0 y 1, y su principal utilidad es la capacidad para evitar mínimos locales de error en la optimización de la red, yendo hacia los mínimos globales, de mejores resultados en la mayoría de los casos. No siempre resulta ventajoso el empleo de este factor, y es el propio sistema quien dictamina mediante pruebas la idoneidad de su uso.

Los otros dos factores ya se han comentado previamente de forma breve, y lo único que se hace es jugar con sus valores, de forma que se llegue a mejores predicciones con un menor número de iteraciones de cálculo, con lo que se optimiza el resultado y el tiempo empleado. El método utilizado es, para la relación de aprendizaje, el empleo de un algoritmo que varía automáticamente su valor hasta hacerlo óptimo, según la variación de errores de una iteración a la siguiente. Para la variación del parámetro  $\alpha$  de la ecuación logística, se emplea el de prueba-error, viendo por eliminación qué parámetros son los más adecuados, mediante sucesivas resoluciones de la red neuronal.

Las decisiones previas realizadas en esta tesis doctoral se esquematizan en los siguientes puntos:

- *Selección del tipo de red neuronal y algoritmo de aprendizaje:* Según bibliografía y ensayos preliminares, se escoge el algoritmo de gradiente descendente con momento en la variación de los pesos. Se mantiene como posible alternativa rápida, para implantación en línea, el algoritmo de Levenberg-Marquardt.
- *Número de capas ocultas:* Los estudios comenzaron por 2, obteniéndose resultados similares con una capa oculta, a la vez que se mejoraron ostensiblemente los tiempos de ejecución, por lo que se ha fijado el número en una capa oculta.
- *El número de neuronas en la capa oculta, el factor de aprendizaje y el momento:* se optimizarán mediante bancos de pruebas detallados en los resultados.

## 4. ANTECEDENTES

### 4.1. APLICACIONES DE LAS REDES NEURONALES

La aplicación industrial de las redes neuronales data de 1960, cuando Widrow y Hoff emplearon la red ADALINE en el campo del procesamiento de señales (Widrow B. y Hoff M., 1960), si bien su empleo se ha generalizado posteriormente a prácticamente todos los campos del conocimiento.

#### 4.1.1. En la industria del fibrocemento

Como ya se ha comentado anteriormente, el empleo de este tipo de técnicas resulta novedoso en la industria del fibrocemento.

#### 4.1.2. En la industria pastero-papelera

Existe un gran número de publicaciones recientes que emplean redes neuronales en la industria pastero-papelera, lo que indica que ésta es un área del conocimiento muy activa actualmente.

La figura 4.1 muestra un diagrama simplificado de una fábrica de papel integrada, en el que se indican las diferentes aplicaciones de las redes neuronales. El proceso se compone de numerosas etapas y en casi todas se han aplicado las redes neuronales.

Los objetivos de las aplicaciones de las redes neuronales son muy diversos e incluyen:

- El control de ciertas secciones del proceso.
- El modelado / simulación de una etapa específica.
- La predicción de propiedades del producto, roturas, estados defectuosos de fabricación o emisiones de contaminantes.

En algunos casos la complejidad de las secciones estudiadas, en otros la comparación con otras técnicas de modelado e incluso otros motivos como la necesidad de implantar sistemas de control robustos, han llevado a diferentes autores al empleo de este sistema de tratamiento avanzado de datos.

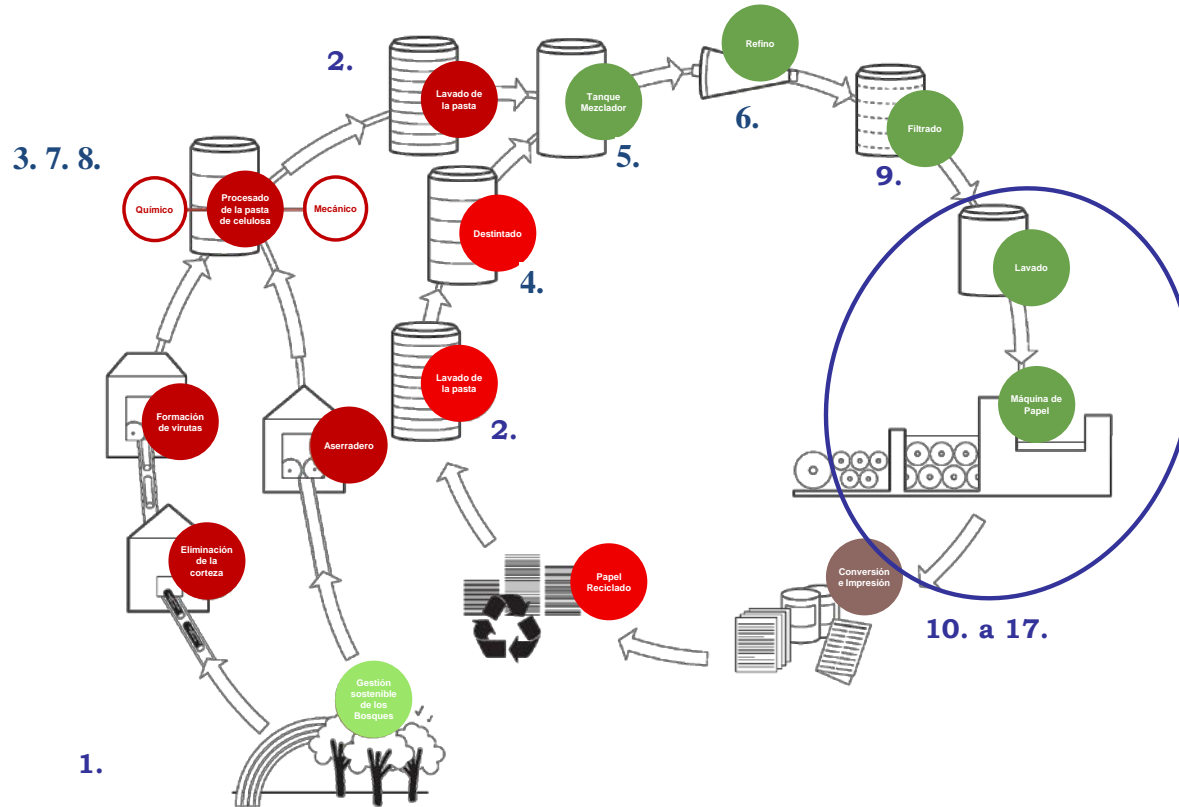


Figura 4.1 – Ejemplo de una fábrica de papel integrada. Las diferentes secciones se señalan según número de referencia del capítulo (4.1.2).

Ante la dificultad de establecer grupos claramente definidos de trabajo con redes neuronales, se ha realizado una revisión de las aplicaciones clasificándolas según las etapas de la fabricación de papel donde se centran. La localización específica de algunos de los trabajos no fue posible, con lo que se han referido o bien a la fabricación en general o bien a capítulos específicos como el análisis de tendencias, datos económicos, consumos energéticos o artículos de teoría matemática.

### **4.1.2.1. Desintegradores de pasta y digestores**

Aunque sean dos secciones claramente diferenciables dentro de la fabricación de pasta y papel, se da la circunstancia de que los trabajos que han tratado estas secciones lo han hecho conjuntamente, incluyendo habitualmente la química de la digestión en una parte más de la desintegración de la pasta. Por ello, se han unido ambas secciones en un solo epígrafe.

La madera es una estructura compleja de fibras, unidas entre sí por la lignina. El proceso Kraft consiste en la eliminación de la lignina mediante su reacción con una lejía compuesta principalmente por hidróxido sódico y sulfuro sódico. Según las condiciones de operación, las fibras se degradarán, blanquearán o protegerán de forma diferente. Se han propuesto algunos modelos para optimizar los procesos químicos de esta etapa, pero la complejidad de estas secciones y su no linealidad hizo pensar a los investigadores en el empleo de herramientas avanzadas, como las redes neuronales, para el control o el modelado de los procesos de desintegración de pasta y digestión de la madera.

Varios trabajos han abordado la predicción del índice Kappa mediante el desarrollo de redes neuronales, su comparación y combinación con modelos físico-químicos, y su combinación con métodos de lógica difusa.

Aguiar y Filho han realizado varios estudios que combinan las redes neuronales con modelos físico-químicos. Han empleado arquitecturas de alimentación hacia delante y algoritmos de retropropagación, empleando el programa "NeuralWork". En su primer trabajo de 1998 construyeron con éxito modelos de una capa oculta para modelar la química de un digestor Kraft. Se observó que los porcentajes de reacción se veían afectados principalmente por la

temperatura y algunas concentraciones medidas. Obtuvieron los mismos resultados empleando modelos determinísticos y redes neuronales, que según ellos tienen la ventaja de no requerir conocimientos previos, mientras que presentan el inconveniente de no poder ser empleadas fuera de las condiciones de entrenamiento. Estos autores han propuesto el empleo de estos modelos para el entrenamiento de operarios e ingenieros y como herramienta de toma de decisiones.

Un segundo trabajo describió un modelo híbrido combinando las dos técnicas presentes en el primer estudio (redes neuronales y modelos determinísticos). Las redes se desarrollaron con algoritmo de gradiente descendente con momento y factor de compensación, 2 capas ocultas de 12 y 10 neuronas respectivamente, y función de transferencia sigmoideal. Las entradas iniciales para el desarrollo del modelo fueron el álcali efectivo total, la temperatura y el factor-H en la parte superior y otros dos puntos internos de medición. Como única salida se tenía el índice Kappa. Una vez más, se consideró que ambas herramientas eran adecuadas y consideraron su modelo como un buen punto de partida. La utilidad final fue de nuevo la posibilidad de entrenar operarios e ingenieros, el empleo de la simulación para la prueba de escenarios del tipo “Qué pasa si...”, y su empleo como herramienta de toma de decisiones.

Se han llevado a cabo trabajos posteriores con redes de la misma estructura y algoritmo de entrenamiento, con el fin de predecir el grado de desintegración de la pasta (Aguar y Filho, 2001). De nuevo compararon los modelos determinísticos con las redes neuronales y los modelos híbridos, con resultados similares. Los trabajos mostraron la necesidad de optimizar los parámetros de las redes desarrolladas, evitar el sobreentrenamiento y emplear datos de elevada calidad, con un procesado previo de medias móviles de 30 minutos.

Las redes neuronales también se han empleado en combinación con la lógica difusa para predecir el índice Kappa con el programa “Neural Works Predict®” (Musavi y col., 1999). Los datos que han empleado provienen de la misma variable, pero utilizándola con distintos retrasos de tiempo como entradas al modelo. Estos autores han desarrollado un sistema neuronal difuso aplicando reglas “si-entonces” en una capa oculta. Con este sistema se ha predicho satisfactoriamente el índice Kappa y se han analizado los coeficientes de correlación para diferentes periodos de entrenamiento. También han establecido un criterio propio para determinar prestaciones buenas o excelentes en los modelos. A los que presentan coeficientes

de correlación entre 0.63 y 0.77 se les llama buenos, mientras que los que tienen un “R” por encima de 0.77 son considerados excelentes.

Los mapas autoorganizados (SOM) son estructuras de redes neuronales en las cuales las neuronas se distribuyen en una malla bidimensional regular. Estos mapas se han aplicado al análisis de datos de desintegración de pasta en la fábrica de UPM-Kymmene Pietarsaari (Alhoniemi, 2000). En este trabajo, el análisis de estados defectuosos y la búsqueda de correlaciones entre el índice Kappa y otros parámetros del proceso, especialmente el factor-H, se han empleado para analizar un digestor continuo. Se ha realizado un procesamiento previo de los datos con una media móvil de 10 minutos. Se ha establecido que el análisis de los datos de desintegración de pasta es la única forma de investigar el comportamiento del sistema en situaciones anómalas. Las variables del caso práctico se han determinado tras un proceso iterativo de minería de datos. Los mapas autoorganizados han sido empleados con gran eficiencia para visualizar las correlaciones existentes entre las distintas variables del proceso.

Aparte de Alhoniemi E. en el año 2000, varios trabajos han estudiado los digestores continuos para, por ejemplo, detectar defectos mediante redes de un solo nodo con medidas del contenido de humedad y la densidad (Dufour y col., 2001). Los autores basaron su estudio en la detección de grandes errores, variaciones en la calidad de la pasta y variaciones en los aportes de materias primas. Concluyeron que las restricciones de tiempo de computación se resolvían trabajando con redes con entrenamiento fuera de línea. Las redes mostraron un buen potencial para la detección de cambios en las propiedades a la entrada del digestor. Otra aproximación llevó a buenos resultados en la ejecución de cambios sobre el contenido en humedad, la densidad de dos tipos de madera y la densidad de las lejías blancas. Esperaban continuar trabajando en una “*Moving Horizon Estimation*” o estimación de horizonte móvil para el problema de la variación en los aportes de materias primas, si bien no hay trabajos publicados al respecto.

No solo se han estudiado los digestores continuos, sino también los discontinuos por cargas (Belarbi y col., 2000). Estos digestores han sido simulados (con predicciones del índice Kappa) con redes neuronales difusas con algoritmo de retropropagación. Para el diseño del controlador de lógica difusa, la red neuronal se entrena en una simulación de lazo cerrado fuera de línea. Las estimaciones han mostrado ser suficientemente flexibles y los resultados han sido prometedores. Se

realizaron cambios en las características de la alimentación para realizar diferentes pruebas.

Sarimveis y col., en 2002, explicaron como emplear redes neuronales con función tipo “radial basis” (RBF: una distribución radial parecida a la gaussiana), junto a una partición difusa del espacio de entrada, para modelar un digestor (mediante la estimación del índice Kappa) y un reactor de tanque agitado continuo (mediante medidas de concentraciones y temperatura). Desarrollaron un algoritmo para determinar tanto la estructura de la red como sus parámetros, empleando un tiempo de computación muy limitado, y experimentaron numerosas ventajas al emplear con su metodología las redes neuronales, ya que dicha metodología requiere un solo pase de los ejemplos de entrenamiento, y no dependía de una selección inicial aleatoria de los nodos internos. Los resultados permitieron optimizar la estructura y parámetros de las redes, minimizar el número de intentos y producir centros de nodos ocultos, con datos diferentes a los ejemplos de entrenamiento.

Un tipo de red neuronal muy poco utilizado, basado en wavelets (ondas canónicas), se ha empleado para determinar el efecto de diferentes variables y parámetros de proceso en la desintegración de pasta de los restos vegetales de la fabricación de aceite de palma (Zainuddin Z. y col., 2011).

#### **4.1.2.2. Lavado de pasta**

Los problemas asociados a las operaciones de lavado encajan como problema ideal para las características de las redes neuronales. El control del lavado de pasta mejoró esta etapa en la fábrica *G-P Ashdown* (Beaverstock y Wolchina, 1992). En el modelado, emplearon redes neuronales diferentes para cada salida. Se consideró que las densidades, consistencias y pérdidas de sosa eran función de las velocidades de los tambores, la dilución, las temperaturas, las presiones y el caudal de materia prima. Los resultados hicieron que los autores consideraran trabajos posteriores que aplicaran las redes neuronales al blanqueo, refinado, digestor y sección de recuperación. Como conclusión afirmaron que las redes neuronales se pueden aplicar con éxito a las operaciones de una fábrica de papel, y que han probado ser un método estable y muy adecuado para aplicar en fábrica el conocimiento de las diferentes operaciones del proceso.

En un artículo de análisis (Patrick, 1991), se dijo que el lavador de pasta era un ejemplo adecuado de aplicación para el control con redes neuronales, debido principalmente a dos razones:

- La falta de métodos adecuados para medida en tiempo real de forma repetible y fiable.
- Los consecuentes retrasos de tiempo que existen en las medidas.

Rudd J.B. ha publicado en dos fuentes distintas (Rudd, 1991a; Rudd, 1991b) la aplicación a escala industrial de redes neuronales de alimentación hacia delante y algoritmo de retropropagación para tareas de control avanzado. Se han empleado para ello medidas de consistencia, peso y pérdidas de sosa. Se emplearon variables obtenibles únicamente con ensayos de laboratorio, con instrumentos de toma de muestra con extenso intervalo de tiempo entre medidas, y variables que reemplazaban a sensores en línea de elevado coste de mantenimiento. Los resultados del empleo de una combinación de:

- Redes neuronales
- Sistemas basados en reglas
- Técnicas matemáticas convencionales

fueron alentadores, y los autores descubrieron múltiples ventajas en su empleo:

- No hace falta programarlas y no requieren conocimiento previo.
- Funcionan incluso con parte de los datos con incorrecciones. Ven más allá del ruido y las distorsiones.
- Tienen gran capacidad de generalización.
- Puede solucionar cualquier problema relacionado con el mapeo de datos de entrada en datos de salida.

La etapa de filtración fue controlada a través de medidas de las pérdidas de sosa, consistencia de la torta y masa específica. Se empleó una combinación sinérgica del control convencional y las redes neuronales. Se desarrolló un grupo de herramientas de aplicación de la ingeniería. Los autores aconsejaron finalmente a los productores de papel el empleo de técnicas de control avanzado. Trabajos más recientes reafirman la capacidad de las redes neuronales en esta etapa (Ray A.K. y col., 2010).

### 4.1.2.3. Blanqueo

La no linealidad general en la industria pastero-papelera se puede aplicar también a esta sección. Algunos autores han pensado en las redes neuronales para el modelado de esta etapa.

Se ha realizado una comparación de diferentes métodos de análisis y control, empleando como ejemplo la etapa de blanqueo de un modelo en Honeywell (Kosunen y col., 1997). Según los autores, se esperaba un gran futuro para las nuevas herramientas de control, pero también advirtieron la necesidad de aplicarlas correctamente, empleando personal con buen conocimiento del proceso. Los objetivos marcados fueron la mejora de calidad, la reducción de la variabilidad y la bajada de los costes de materiales. Las últimas soluciones de control avanzado probaron ser capaces de proporcionar beneficios sustanciales a las fábricas de pasta, como se resumirá posteriormente. La deslignificación en dos etapas también fue modelada (Pulkkinen y col., 1997), empleando el programa “Alcont” (especialmente sus cajas de herramientas de control difuso y control con redes neuronales). En este caso, la desviación del índice Kappa se redujo en un 25%.

El programa “NeurON Line” de la empresa Gensym® se ha empleado para desarrollar un sensor virtual, basado en redes neuronales, para el control de la blancura en la etapa de blanqueo con dióxido de cloro (Vaughan y col., 1999). La ecuación 12, donde “H” representa el número de neuronas ocultas, “I” el número de entradas y “O” el número de salidas, fue propuesta para el cálculo del tamaño mínimo de las matrices de datos en el modelado “MDS”. El modelo creado ha probado ser un excelente método de predicción de la blancura final, permitiendo una optimización que controle su variabilidad. Se han obtenido beneficios significativos que se verán más adelante.

$$MDS_{\text{tamaño}} = \frac{H(I+1) + O(H+1)}{O} \quad (12)$$

Otro ejemplo del éxito al aplicar una metodología apropiada con redes neuronales en la etapa de blanqueo lo supone el trabajo de Zhu J. y col. en 1997. Los autores definieron las etapas del modelado, y explicaron con detalle la preparación de los datos, su recolección, procesado previo y revisión. La calidad del

modelo se evaluó por medio de los coeficientes de correlación y de gráficos de comparación de las salidas de los modelos con los datos del proceso. Se realizó y probó también la implementación en un sistema de control distribuido. Se consideró a las redes como sistemas válidos de modelado de sistemas complejos no lineales. Los coeficientes de correlación para las etapas analizadas y los modelos globales fueron todos mayores de 0.8, lo cual se consideró satisfactorio. Hubiese sido útil presentar también los errores absolutos junto a los coeficientes de correlación, para comprobar la utilidad del modelo, por ejemplo, para el filtrado de ruidos o la predicción de tendencias específicas.

Keski-Santti J., en 2007, realizó un estudio sobre la viabilidad y éxito del empleo de redes neuronales en esta sección, midiéndolo en términos del ahorro de costes en dos líneas de producción de Cenibra, estimados en casi 2 millones de euros al año. En 2010, Mine y col. optimizaron el proceso de delignificación mediante oxígeno, estabilizándolo y mejorando la predicción del índice *kappa*.

#### **4.1.2.4. Destintado**

La optimización de los procesos de destintado puede ir asociada al conocimiento del contenido cromático de la pasta. Verikas y col. han aplicado el análisis de imagen para la monitorización del proceso de destintado por medio de la clasificación de motas de colores en la pasta que se encuentra en fase de refino. Dicha clasificación ha sido realizada con perceptrones multicapa, mapas autoorganizados y lógica difusa (Verikas y col., 2000; Verikas y col., 2001). La necesidad de un nuevo sistema de análisis se ha debido principalmente a dos razones:

- En los analizadores previos en blanco y negro, el número de motas en la pasta se estimaba a la baja.
- Según el color de las motas, su blanqueo se puede realizar con diferentes aditivos químicos.

Se afrontaron con éxito los problemas del procesado previo de los datos y, por tanto, se llevó a cabo un buen reconocimiento de los diferentes tipos de motas. Ambos trabajos presentan una visión similar del problema, llegando a conclusiones también similares. La clasificación por colores se correspondió bien con la percepción humana, y solo una pequeña fracción de las manchas se clasificaron como de color negro. Se desarrollaron mapas autoorganizados de una dimensión y

16 nodos, y de dos dimensiones con 7x7 nodos. Las funciones de pertenencia a grupos se explicaron con detalle.

Otro objetivo cuando se optimiza el destintado es la optimización del nivel del tanque de mezcla. Se ha analizado tanto este nivel como su influencia sobre la blancura del papel (Broeren y Smith, 1996). El objetivo primario era la reducción de los costes de aditivos químicos en el desintegrado de la pasta, a la vez que se mantenía la blancura. Este objetivo se cumplió satisfactoriamente, y se concluyó que el trabajo con herramientas potentes de optimización (se citaron las redes de tal forma), y un gran número de entradas (hasta 66, empleadas para diversos análisis), sirvió para el reconocimiento del nivel del tanque de mezcla como una variable altamente influyente. En un primer estudio con el nivel mantenido alrededor del 60%, su influencia sobre la blancura se clasificó la 62ª de 66 variables. Durante las últimas dos semanas del estudio, se varió al azar el nivel del tanque de mezcla entre el 52% y el 85%. En este caso, su influencia fue la 2ª más importante de las 59 variables estudiadas. Si se hubiera empleado una herramienta menos potente, el nivel no se habría incluido en el análisis de optimización.

##### **4.1.2.5. Mezclado**

Las operaciones llevadas a cabo en una fábrica de papel están siempre relacionadas con fluidos no newtonianos y con fluidos de elevada viscosidad. Esto hace que el modelado empírico revista una gran dificultad. Las redes neuronales, de nuevo, fueron consideradas útiles para afrontar el modelado de la dinámica de fluidos, y se desarrolló un modelo para el mezclado con estas herramientas (Virkki-Hatakka y Bulsari, 2002). Para modelar la velocidad superficial se emplearon como entradas la velocidad rotacional del impulsor y la viscosidad del fluido. Una red neuronal creada a pequeña escala se empleó para el modelado a escala industrial. La principal conclusión de este intento fue que cuanto más pequeños fuesen los cambios, mejor resultaba el modelo a escala. Con este estudio se consiguieron grandes ahorros de tiempo y dinero.

##### **4.1.2.6. Refino**

El grado de refino es una propiedad física de la pasta de gran importancia, ya que ayuda a clasificar pastas diferentes según la ramificación de sus fibras y

microfibras. El método más extendido para la medida del grado de refino es el “*Canadian Standard Freeness*” o CSF, presente en prácticamente todas las fábricas de papel. La importancia del grado de refino en la formación de la hoja hace que éste deba ser controlado. Las redes neuronales de funciones de base radial (RBF), junto a controladores de lógica difusa, se han empleado a tal efecto (Bard y col., 1999). En este estudio se obtuvieron buenas predicciones del CSF a partir de medidas de variables de proceso como las presiones, los caudales, el consumo energético y las consistencias. La combinación de las redes y el controlador difuso se consideró un buen método no intrusivo de determinación del grado de refino. El control tenía por objetivo alcanzar un grado de refino de  $630 \pm 5$  mL. Se propusieron trabajos posteriores para la realización de un control de lazo cerrado en el refinador a escala industrial.

Se han empleado distintos sistemas de control para controlar el refino en una fábrica de pasta termomecánica (Sui y col., 1998), explicando la metodología empleada y los detalles de las entradas y salidas, con las siguientes variables: refino, consistencia en el refino, predicción de la calidad de la pasta, control de calidad automatizado del hueco entre platos, y mejora de la estabilidad y de la calidad del proceso. Se empleó el algoritmo de Levenberg-Marquardt para construir, con más del 90% del tiempo incluido, un modelo a largo plazo construido a partir de una base de datos (histórico) de 60 días, y otro modelo a corto plazo a partir de un histórico de 14 días. La calidad predicha de la pasta se calculó como la media de todos los modelos desarrollados, cuyos parámetros se podían modificar en línea. El objetivo final era el control de la calidad proporcional, integral y diferencial, de lazo cerrado, en una fábrica de papel prensa, técnica multivariable de control que fue aplicada con éxito en todas las líneas de refino de la fábrica. Se constató la confianza de los operarios en el sistema de control y se redujo la desviación estándar del grado de refino en un 50%. Otros beneficios asociados fueron la mejora de la estabilidad en la producción, una menor cantidad de alarmas y el alargamiento de la vida de los platos. El éxito de este modelo les llevó a emplearlo en otras operaciones de la fábrica.

El diseño “*D-Optimal*” se emplea habitualmente para completar series de experimentos de forma óptima. Los datos de la primera y segunda etapa del refino, así como de la zona intermedia, se han empleado en diseños D-Optimal, y se han tratado con redes neuronales del tipo RBF y de alimentación hacia delante (Lanouette y col., 1997; Lanouette y col., 1998). Las entradas a los modelos fueron, en la primera etapa de refino, la temperatura de funcionamiento del digestor y el

hueco entre platos, el tratamiento con hidróxido sódico (variable booleana), la carga de peróxido de hidrógeno, la temperatura y el tiempo de retención en la etapa intermedia; y la consistencia en la segunda etapa. Se emplearon fibras de *pinus banksiana*, y las respuestas (Blancura ISO y otras propiedades superficiales) fueron evaluadas según se variaba el número de neuronas. Para este propósito las redes RBF dieron mejores resultados que las de alimentación hacia delante con funciones normales. Como las redes RBF se mostraron muy robustas en la elección del número de centros para el diseño D-Optimal, se concluyó que no hacía falta reducir el número de entradas al modelo, lo cual supuso una ventaja significativa.

En trabajos posteriores (Thibault y col., 2003), se empleó el método de “*rough set*” y el dominio de Pareto, que proporcionaron información complementaria muy útil. Se emplearon las mismas entradas a los modelos, pero las salidas consideradas fueron la blancura ISO, la energía específica de refino, la energía de tracción en la adsorción y el índice de desgarrado. Los “*Rough sets*” se emplearon para optimizar el proceso de desintegrado termomecánico de alto rendimiento de las fibras del pino de Banks. Las salidas consideradas en el estudio de optimización fueron la blancura ISO, la energía específica de refino, el contenido en extractivos y la longitud de rotura. Los resultados sirvieron para determinar que se prefiere el tratamiento en la etapa intermedia con NaOH a la ausencia de dicho tratamiento.

Algunos trabajos presentan entornos de modelado fáciles de emplear, que podrían ser utilizados en una fábrica. En estos casos, las tareas de modelado pasan a un papel secundario. El programa CadSim Plus se ha empleado para modelar el CSF y la energía de refino, así como el índice de desgarrado y la blancura ISO (Laperrière y Wasik, 2001). Se utilizó un diseño de experimentos Box-Behnken, y se estableció la forma de trabajo con redes de alimentación hacia delante en un entorno de simulación. También se describe cómo implementarlos en un programa de simulación comercial. La facilidad de empleo fue una de las ventajas de la caja de herramientas implementada. El trabajo prevé una generalización de la estructura de perceptrón multicapa empleada, para la inclusión de sistemas dinámicos incluyendo la dimensión temporal. Los autores continuaron posteriormente sus estudios empleando el método *Downhill Simplex* (Laperrière y Wasik, 2002). El mismo programa se empleó posteriormente para simular el refino de una fábrica de pasta termomecánica (Li Y. y col., 2007).

Otra aproximación al tema comparó diferentes topologías de redes neuronales (Schweiger y Rudd, 1994). Las redes neuronales de atención enfocada se presentaron como un método aventajado frente a las redes más tradicionales, debido a que tienen en cuenta la presencia de entradas correlacionadas o problemas de control con variables dependientes. Se construyó un modelo intermedio con este tipo de redes, en el que los datos del refino y de la resistencia en húmedo se emplearon para el control del “*Concora Medium Test*” (CMT) y la porosidad. Las entradas se clasificaron de acuerdo con sus sensibilidades relativas respecto a las salidas. Las variables que más influían sobre el CMT fueron el gramaje, la presión en la caja de entrada y la velocidad de bobinado, mientras que la porosidad se veía afectada principalmente por la presión en la caja de entrada, seguida del caudal de la resistencia en húmedo, el nivel del tanque de mezcla, la velocidad de bobinado, el gramaje y las cargas del refino N° 283, todos ellos con sensibilidades parecidas. Se construyeron modelos totalmente no lineales y dinámicos sin ninguna información de los principios físico-químicos gobernantes, y estos modelos se emplearon para establecer nuevas recomendaciones para los puntos de consigna. Se propuso una discusión acerca de la metodología para “invertir” la dinámica de la planta. Los resultados mostraron una gran estabilización de los valores del CMT y la porosidad. En un trabajo similar (Rudd, 1994), se realizó un análisis detallado de los errores y predicciones obtenidos al controlar el CMT.

Un caso distinto de refino, el de astillas de madera, también ha sido controlado mediante redes neuronales tanto estáticas como dinámicas, evaluando y clasificando los errores de control (Kooi y Khorasani, 1992). Se constató, lógicamente, que en procesos sin comportamientos dinámicos de variación rápida, el controlador estático de redes neuronales se comportó de modo satisfactorio, mientras que al tener un proceso no lineal de dinámica de variaciones rápidas, las redes neuronales dinámicas tuvieron un mejor comportamiento. Las redes de alimentación hacia delante, con algoritmo de retropropagación y una capa oculta se comportaron mejor que las de dos capas ocultas al modelar el refino con medidas de la energía específica, la consistencia, la longitud de fibra, la fracción de fibras largas y el grado de refino (Qian y col., 1995). Se concluyó que las redes neuronales podían ser empleadas en el modelado de estado estacionario y en la optimización de procesos industriales complejos, incluyendo el refino de las astillas de madera, dada la dificultad de desarrollar un modelo mecánico.

#### 4.1.2.7. Calderas, emisiones y corrientes residuales

Las diferentes normas de emisiones se están volviendo cada día más estrictas y, por tanto, los directivos de fábricas de pasta y papel han de afrontar decisiones relativas a los métodos y tecnologías que serán empleadas para cumplir las regulaciones ambientales. Las emisiones se ven afectadas por numerosos parámetros y, por tanto, algunos autores han pensado emplear redes neuronales para predecirlas o controlarlas.

Varios trabajos han estudiado las emisiones de las calderas. Algunos las estudian para estimar la posibilidad de su monitorización empleando redes neuronales (Baines y col., 1997), en una aproximación al tema de forma superficial con el programa de Gensym llamado "*NeuroOn-Line Studio*". También se han empleado optimizaciones de una serie de calderas (DeCicco, 2001). En este trabajo se considera el empleo de la ingeniería "del sentido común", empezando por una formulación adecuada del problema de optimización, preprocesando los datos, evaluando el modelo y, al final, obteniendo los resultados de la optimización.

Otros trabajos que analizan a la vez las calderas de energía y de recuperación. Horton R.R. y col., en 1998, predijeron las emisiones de TRS (el total de compuestos de azufre reducidos),  $SO_2$ , CO y  $NO_x$  en un periodo de prueba, con diferentes condiciones de operación, y optimizaron el proceso mediante análisis de sensibilidad sobre las entradas. El caudal de sólidos en las lejías negras y el caudal de aire terciario fueron las variables más influyentes sobre el modelo de porcentaje de  $O_2$ . El caudal de sólidos en las lejías negras fue la variable que más influía sobre las emisiones de  $NO_x$ . El oxígeno en chimenea fue el factor más influyente, de lejos, sobre las emisiones de CO. De nuevo el oxígeno en chimenea y las temperaturas de gases influían sobre las emisiones de TRS y, finalmente, el caudal de aire secundario y la presión en la boquilla de lejías negras influían sobre las emisiones de  $SO_2$ . Se mostró que las redes neuronales pueden ser también empleadas como sistemas de monitorización paramétricos para el control en línea de optimización. Se destacó que, con sistemas DCS avanzados y una disponibilidad elevada de datos históricos, las redes neuronales se hacen todavía más prácticas. Sugirieron que una prueba más rigurosa podría incrementar el intervalo de condiciones de operación modelables. Se aumentó en un 3% el ratio medio vapor-lejía negra en condiciones óptimas, y la emisión de CO media decreció, incluso decreciendo el aire total empleado. Se obtuvieron resultados y conclusiones similares en otro trabajo publicado en 1999.

Más tarde, en 2001, realizaron un estudio completo que incluía comparaciones con regresión múltiple no lineal, empleando el programa “*Process Insights*” (Horton y Shuman, 2001). El coeficiente de correlación más elevado se obtuvo con las redes neuronales, pero tanto las redes como la regresión múltiple no lineal proporcionaron resultados suficientemente buenos como para cumplir los requerimientos de las regulaciones necesarias. Se escogió la regresión múltiple no lineal, ya que presentaba una precisión suficiente, pero implicando menores costes y únicamente cuatro sensores. Se indicó que este modelo era más fácil de mantener e implementar en un DCS. Ante tales afirmaciones surge una pregunta: ¿Qué resultados se hubiesen obtenido si se hubiese construido una red con las mismas entradas que el modelo de regresión múltiple no lineal? ¿Podría haber cambiado las conclusiones una comparación entre tales modelos? También podría haberse tenido en cuenta la posibilidad de implementar las redes neuronales y actualizarlas con el tiempo.

En 2012, de Almeida y col. han empleado el análisis de datos multivariante basado en una red neuronal para detectar anomalías de funcionamiento en la caldera de recuperación, mostrándose prácticamente indispensable frente a otros sistemas clásicos de análisis con una sola variable.

Las emisiones de azufre han sido las más estudiadas dentro de esta etapa. Se ha desarrollado una red de alimentación hacia delante, con dos capas ocultas de 80 y 50 neuronas, con algoritmo de retropropagación, para modelar las emisiones de TRS y SO<sub>2</sub>, en una caldera de recuperación de un proceso Kraft (Smith y col., 2000). Se pensó en las redes neuronales para modelar estas emisiones, de naturaleza compleja. Si se hace funcionar el modelo en una aplicación en tiempo real, se afirma que puede ayudar a asegurar que la unidad se comporta en condiciones predecibles. En caso de presentarse un comportamiento inusual, la red neuronal se podría emplear para asesorar sobre las causas subyacentes y ofrecer unas recomendaciones guía. La posibilidad de actualizar estos modelos con el tiempo se citó como una ventaja considerable.

También se han estudiado las emisiones del horno de cal (emisiones de TRS) para su reducción mediante modelado matemático, comparando modelos lineales y redes neuronales (Järvensivu y col., 1998). Se observó que las emisiones de TRS estaban directamente relacionadas con una función de, por una parte, el lavado de los lodos de cal y la operación de filtrado y, por otra, las condiciones de

combustión en el horno. Se realizaron otros análisis de las relaciones entre las variables estudiadas. Se propuso la construcción de un sistema de validación del analizador de TRS con un propósito de mantenimiento y, aparte, comprobar la influencia de los cambios de condiciones de operación, así como señalar las causas de emisiones de TRS basándose en las medidas disponibles. Se probaron diferentes alternativas para la reducción de las emisiones de TRS en las etapas de filtrado de lodos, lavado y desgote, oxidación con sulfuro sódico, horno de cal, tratamiento al final de la tubería o el lavado de los gases de chimenea. La reducción del contenido de álcali residual, debida al incremento en el caudal de agua de lavado, fue muy significativa. El agua de lavado ha de cumplir unos límites muy definidos en el filtrado a escala industrial.

En trabajos posteriores, se ha controlado el horno de cal, reduciéndose los costes energéticos en un 7%, las emisiones de TRS en un 10%, y la proporción de periodos con emisiones elevadas en un 50% (Järvensivu y col., 2001). También se mejoró la estabilidad operacional, y se recomendó la instalación de alarmas inteligentes. Este trabajo supone un buen ejemplo en la descripción de los detalles de un modelo. Se describieron con gran detalle los controladores de alimentación hacia delante, contruidos con redes neuronales con algoritmo de retropropagación, mostrando incluso los pesos internos en cada capa. Se describió la metodología para el control del horno de cal, y se sugirió el empleo de sistemas inteligentes similares en otros procesos industriales, mencionando que éstos, unidos al conocimiento experimental del comportamiento del proceso, pueden proporcionar beneficios considerables.

La calidad de las lejías verdes también ha sido controlada en un proceso Kraft, empleando espectroscopia de infrarrojo cercano y modelando con redes neuronales, con algoritmo de retropropagación, y análisis de componentes principales (Lampe y col., 2001). Los autores diseñaron, en colaboración con Siemens, un sistema de medida en línea para la fábrica de *Iggesund Paperboard*. Construyeron los modelos, pero dejaron el desarrollo de modelos de calibración para siguientes trabajos. Se empleó el espectro de lejías artificiales para predecir el contenido de  $\text{Na}_2\text{CO}_3$ ,  $\text{Na}_2\text{SO}_4$ ,  $\text{Na}_2\text{S}$  y el grado de reducción.

Uno de los autores de aquel trabajo, Herbert Furumoto, ha publicado varias patentes trabajando para Siemens, relacionadas con el empleo de redes neuronales para la operación de una planta de pasta destintada, más específicamente, para la suspensión de papel reciclado (Furumoto, 1998). En esta patente se proporcionan

las entradas y salidas empleadas en el modelo, así como una descripción en detalle de la metodología empleada. También se ha patentado la metodología para el manejo del proceso de fabricación de papel y cartón mediante redes neuronales (Furumoto y col., 2001), así como los métodos de medida del contenido en lignina (Furumoto, 2002). Laitinen-Vellonen también ha publicado en 2001 otra patente relacionada con la metodología para la monitorización y análisis de un proceso de fabricación de papel, empleando redes neuronales.

Otra medida estudiada ha sido la demanda biológica de oxígeno (DBO), en este caso, en el tratamiento de aguas residuales, empleando regresiones de componentes principales, redes neuronales combinadas con análisis de componentes principales (PCA), y redes neuronales en solitario (Oliveira-Esquerre y col., 2002). Se ha empleado el programa "NeuroSolutions Professional". La combinación de redes neuronales y análisis de componentes principales proporcionó los mejores resultados. Se citó la ventaja de las redes neuronales, por su gran habilidad para representar relaciones altamente no lineales. Al compararlas con métodos estadísticos, se ve que las redes proporcionan un marco más general de determinación de relaciones entre los datos.

Xie y col., en 2003, llevaron a cabo la clasificación del tipo de flujo dentro de la línea de tratamiento de residuos a partir de medidas de las fluctuaciones de la presión. El modelo tenía que distinguir entre flujo burbujeante, flujo pistón, flujo turbulento y flujo "pegajoso", utilizando como entradas medidas tratadas estadísticamente de la presión. Se desarrollaron dos redes neuronales de alimentación hacia delante, la primera con una sola salida (indicador del tipo de flujo), y la segunda con 4 salidas diferentes, una para cada tipo de flujo. Todas las malas clasificaciones ocurrieron entre flujos de características adyacentes. El clasificador de tipo de flujo basado en un único sensor de presión resultó viable para numerosos sistemas industriales, según las conclusiones. Se recomendó la verificación experimental en los sistemas industriales.

Martinelli S.H.S. y col., en 2008, emplearon las redes neuronales para detectar defectos en el sistema secundario de aire en una caldera de recuperación, así como para clasificar los residuos, consiguiendo errores muy contenidos en un periodo de estudio de 14 meses.

#### **4.1.2.8. Lavado de gases/líquidos**

Las corrientes gas/líquido se encuentran en un gran número de procesos industriales. En la industria del papel, se ha modelado un lavador empleando el programa “*NNToolbox*”, empleando redes neuronales de alimentación hacia delante con algoritmo de Levenberg-Marquardt y una capa oculta (Milosavljevic y Heikkilä, 1999). Se ha optimizado el número de neuronas, probando varios casos, para tener un valor óptimo de 7 (al emplear más neuronas se tenía un aprendizaje excesivo), y se han comparado los resultados con un modelo físico. Las entradas han sido tanto la proporción de caudal másico como la temperatura y humedad del aire de entrada; la proporción de caudal másico del agua, su temperatura en la entrada, la altura de la columna y la presión en las boquillas tipo spray. La salida ha sido la temperatura del aire de salida. Las redes neuronales proporcionaron más precisión que los modelos físicos, que podrían conducir a reducciones en los costes de equipos y una mejora en la eficiencia energética en el aire húmedo lavado. Un proyecto de similares características en la sección de secado podría llevar a ahorros mucho mayores en el consumo energético, así como a una calidad del producto más estable.

#### **4.1.2.9. Parte húmeda de la máquina de papel**

La parte húmeda de la máquina de papel, es decir, la sección de formación y de prensas, es una sección crucial para las propiedades del producto final, como por ejemplo, la formación de la hoja. En esta sección tienen lugar numerosos mecanismos físico-químicos complejos y no lineales, como es el caso de la floculación, y muchos de ellos todavía no están descritos con suficiente detalle. Por tanto, la parte húmeda resulta otro campo adecuado para el desarrollo de redes neuronales con objetivos de modelado, predicción de la calidad del producto o control del proceso.

Existe una gran variedad de trabajos relacionados con la parte húmeda de la máquina. Pillai B., en 1999, en su tesis doctoral, llevó a cabo la adaptación de las redes neuronales y la lógica difusa al control del final de la parte húmeda, explicando cómo construir las herramientas de modelado y predicción. Se incluyó el modelado de distintos aspectos en la físico-química del final de la parte húmeda, construyendo sistemas de control mediante predicciones, basado en modelos. Se cumplieron los objetivos propuestos, y se constató un beneficio potencial para la industria bastante significativo.

Dentro de la parte húmeda, el proceso de retención es uno de los procesos más estudiados. En esta sección se ha aplicado el modelado semi-físico (Rooke y Wang, 2002), entendiendo como tal a un modelo con una parte física, para la concentración en la alimentación de la caja de entrada, y otra compuesta por perceptrones multicapa, para la evolución, bastante compleja, de la concentración de las aguas blancas. Las entradas fueron: la dosis de polímero, la dosis de cargas minerales, el gramaje, la velocidad de máquina y pH, temperatura y conductividad en la caja de entrada. Los autores obtuvieron como conclusión que se requería un mejor entendimiento del mecanismo de arrastre del papel a escala microscópica. El modelo semi-físico mostró combinar las capacidades de ambos métodos. Se comentó la posibilidad de realizar modelos en línea e incorporar sistemas sofisticados de medida de la química del final de la parte húmeda, como el sistema WIC100.

La formación ha sido estudiada por Scharcanski y Dodson en sus trabajos. Estos autores comenzaron construyendo un simulador mediante ecuaciones, y entonces emplearon las redes neuronales (Scharcanski y Dodson, 1995). Observaron la variación estocástica en el índice de formación, comparándolo con los resultados de la simulación, y concluyeron que se necesitaban grandes cantidades de datos. Se mostró que se podrían llevar a cabo trabajos posteriores para estimar las propiedades físicas del papel, basándose en datos empíricos y en los resultados de la simulación.

En un segundo trabajo, se describió un modelo detallado sobre la formación dinámica, combinando de nuevo las redes neuronales y la simulación (Scharcanski y Dodson, 1996). El objetivo a largo plazo fue la creación de un programa de simulación sencillo de usar, cuya aplicación fuese la resolución de problemas y la aplicación de lazos de control en máquinas de producción de papel. Se modelaron las capas de una fibra y las estructuras de la red de fibras. Se propuso continuar con el empleo de estructuras multicapa. Otros autores han seguido con estudios sobre el control de la formación a alta presión empleando redes neuronales (Kumar R. y col., 2009; Kumar R. y col., 2010).

Las posibilidades de la aplicación de redes neuronales en el final de la parte húmeda fueron referenciadas por Stapley y col., en 1997. Consiguieron una importante reducción de los costes destinados a aditivos químicos, como se verá más adelante. La mezcla de las redes neuronales y la experiencia de los técnicos

del proceso se propuso como una herramienta poderosa para la optimización de procesos de producción de pasta y papel.

La dispersión de las fibras se ha controlado también con redes neuronales (Welp y col., 2002). Se representó el error frente al número de neuronas en cada capa oculta y el número de iteraciones de entrenamiento. Dividieron la aplicación de un controlador con redes neuronales en cuatro pasos, que son la fase de preparación, la de concepción, la de simulación y, finalmente, la de aplicación. Los resultados se consideraron adecuados para el manejo automático de los sistemas de dispersión de fibras.

Las redes neuronales, junto a los algoritmos genéticos y el método de mallado de forma libre se emplearon, con medidas desde el final de la parte húmeda hasta el bobinado, para predecir y optimizar el encolado (Plouff, 2002). El autor empleó el programa "iMODEL" de la compañía Biocomp Systems Inc.

En 2011, Rajesh K. y col. Desarrollaron con éxito una estrategia de control de la retención a través de la simulación de un PID clásico combinado con una red neuronal con algoritmo de retropropagación.

En nuestro Grupo de Investigación se están llevando a cabo numerosos trabajos para optimizar la calidad del papel a partir de medidas en el final de la parte húmeda. Se han visto ejemplos de predicciones de la calidad del papel (Blanco A. y col., 2005a; Blanco A. y col., 2005b; Alonso A. y col., 2005; Alonso A. y col., 2006; Blanco A. y col., 2009), y se ha optimizado el tratamiento avanzado de datos y los procedimientos de validación (Blanco A. y col., 2005a; Blanco A. y col., 2005b; Alonso A. y col., 2005). Los resultados de todos estos trabajos, unidos a los resultados y la experiencia previa de los autores en el manejo de modelos similares en la industria del fibrocemento (Negro C. y col., 2005; Negro C. y col., 2006; Alonso A. y col., 2006), han servido de base para la elaboración de la presente tesis doctoral.

#### **4.1.2.10. Sección de prensado**

La sección de prensado ha sido estudiada por Al-Mutawa y Moon, en 1994, en un trabajo en el que se controló el color empleando redes neuronales de tres capas ocultas, con el programa "NeuralWorks". Se realizó un análisis cualitativo de

la influencia de cada entrada en los modelos, a través de un estudio de los signos de los pesos internos, con unas pocas referencias cuantitativas sobre el comportamiento de la tinta. Las redes se emplearon según una metodología llamada "Connectionist Expert System", de la que se definieron sus propiedades y estructura. El empleo de una red neuronal con tres capas ocultas es bastante inusual, y el análisis de pesos realizado parece ser útil únicamente para el análisis cualitativo de signos de los pesos. No obstante, este análisis de signos hay que analizarlo muy cuidadosamente, ya que el elevado número de combinaciones y suma de efecto presente en tres capas ocultas hace que el signo del resultado final, en muchos casos, no sea lo suficientemente claro.

La sección de prensa ha sido estudiada a través de sensores de humedad, con redes neuronales con algoritmo de retropropagación (Cristini y col., 2003). Los autores desarrollaron y presentaron en detalle la herramienta de medida de la humedad Presecan, considerada adecuada para un control continuo en línea. Todas las particularidades de su empleo se describieron en este artículo.

#### **4.1.2.11. Parte seca de la máquina**

En esta sección de la máquina de papel se ha empleado un perceptrón multicapa para la detección de defectos en la hoja formada, con el fin de alcanzar la norma ENCE 404, más restrictiva que el método TAPPI T213an-89 y la norma ISO 7213 (Campoy-Cervera y col., 2001). Las imágenes se han tomado con el sistema INSPULP, instalado en fábrica. La velocidad de la línea ha sido de 92.3 m/min, y la resolución de 10 píxeles/mm. Las normas se han cumplido y los modelos desarrollados fueron capaces de funcionar en más de una línea de producción, aumentando así la cantidad de superficie analizada de un 0.0017% a un 0.12%. Se propusieron trabajos en los sistemas de protección, mantenimiento, movilidad y flexibilidad para unas pocas líneas con diferentes texturas producidas.

La combinación de redes neuronales e inspección visual fue también llevada a cabo por Carvalho y col., en 1998. En su trabajo, las redes neuronales ayudaron a reducir el ruido en las entradas. Se presentó el "*path method*" o método de la trayectoria, que fue definido, y cuyo algoritmo se dio a conocer en detalle para cada cluster identificado. Los autores consideraron que su método era robusto, capaz de corregir información con ruido, introducida en el modelado, y sugirieron aplicarlo en diferentes áreas.

#### **4.1.2.12. Calandrado**

Se ha descrito un sistema de cálculo para la calandra, empleando una red neuronal (Leppäkoski, 2001). En esta patente finlandesa, como en el resto de patentes revisadas, se describe la metodología empleada, pero no se proporcionan datos específicos ni del proceso ni de la red neuronal.

#### **4.1.2.13. Roturas de la hoja**

La predicción de roturas mediante redes con algoritmo de retropropagación ha sido descrita por una patente estadounidense (Bonissone y col., 1997), así como la combinación de las redes neuronales con el análisis de componentes principales, para reducir el número de entradas al modelo (Miyanishi y Shimada, 1998). En este trabajo se compararon la regresión de componentes principales, los métodos estadísticos y las redes neuronales con algoritmo de retropropagación. El número de roturas al mes decreció de aproximadamente veinte a cinco. El modelado con redes neuronales hizo que la fábrica tomara una gran variedad de acciones como respuesta, por ejemplo el control automático del pH mediante adición de ácido sulfúrico, se escogió un agente de control del limo, se ajustó el aporte de alumbre y se continuó con el empleo de adyuvantes a la retención. Como consecuencia, se obtuvieron notables beneficios, como se verá más adelante.

Saarela A., en 2008, desarrolló para ABB Oy un analizador de defectos en la pasta empleando una red de tipo SOM para clasificar los defectos en las imágenes tomadas por un sistema de alta resolución capaz de llegar a una resolución de 12 píxeles por mm de fibra. Ruuska H., en 2009, publicó un estudio similar basado en sistemas de inspección en línea que, de nuevo, suponían beneficios significativos.

#### **4.1.2.14. Calidad del papel**

Existen multitud de propiedades del papel que pueden ser predichas u optimizadas con diferentes objetivos para los diversos tipos de papel. Las publicaciones revisadas normalmente se centran en propiedades específicas, centrándose en secciones concretas para intentar regularlas. Estas publicaciones se

ubican en esta revisión según la sección estudiada. Pero en algunos casos, las medidas no son tan específicas, y la publicación se centra simplemente en las propiedades, más que en la sección analizada. Se han encontrado numerosos ejemplos de publicaciones centradas en las propiedades del papel.

Por ejemplo, en los valores del “*Hercules Size Test*”, la opacidad y la resistencia a la tracción han sido predichas a partir de medidas de la cantidad de encolantes, cargas minerales, almidón, pH, gramaje y CSF (Gyaneshwar y col., 2000). Los autores indican que el empleo de sistema de múltiple entrada y múltiple salida (MIMO) es la elección más adecuada. El programa “*Process Insights*”, ya utilizado en la sección de calderas, también se ha empleado para predecir las propiedades del papel (Lenz y col., 2001). Se han descrito las etapas y la metodología de trabajo a escala de fábrica. Las redes neuronales se han empleado numerosas veces en la fábrica “*Locks*” como una herramienta de resolución de problemas y para proporcionar conocimiento sobre problemas de maquinabilidad.

El mismo programa ha sido empleado para obtener predicciones de la DBO en un trabajo con el premio “*George Olmsted*” (Masmoudi, 1999). Las entradas se tomaron de áreas muy diversas dentro de la fábrica de papel. Se realizó un análisis de sensibilidad para la selección de las entradas más influyentes, y las redes neuronales de alimentación hacia delante, con adición de factores de corrección de tendencia (conocidos por el anglosajón “*bias*”), fueron implementadas satisfactoriamente. Los valores predichos de DBO se encontraron en un intervalo del  $\pm 10\%$  de los valores de DBO reales.

Es común el encontrar comparaciones de las redes neuronales con técnicas alternativas. Phung y Nguyen, en 2003, aplicaron técnicas de minería de datos para predecir la calidad del papel. Compararon las redes neuronales, el método de mínimos cuadrados parciales y una mezcla de ambas técnicas. Las redes neuronales tuvieron los mejores resultados, pero esto puede depender de la aplicación. Se señaló a los mínimos cuadrados parciales como el método más sencillo de empleo, mientras que a las redes se las definía como el modelo menos entendible, consideradas como cajas negras. La mezcla de redes y mínimos cuadrados parciales eliminaba problemas de redundancia, pero proporcionaba peores resultados que las redes en solitario. Se incluyó una descripción del preproceso de datos, mostrando que:

- Los eventos con datos perdidos deben ser borrados o rellenados con datos calculados con la media de los existentes.
- Las variables que no cambian no deben ser empleadas.
- Los datos erróneos deben ser eliminados.
- Se acepta un grupo de datos de entrenamiento si el coeficiente de correlación es superior al 50% y si los errores de validación no tienen más de un 20% de diferencia respecto a los de entrenamiento. Las variables menos influyentes fueron eliminadas por mínimos cuadrados parciales.

Los programas NeuroShell y Genehunter se han empleado para desarrollar redes neuronales de alimentación hacia delante y algoritmos genéticos, con el objetivo de optimizar la blancura del cartón pintado a partir de medidas de la adición de materias primas (Kumar y Hand, 1999; Kumar y Hand, 2000). En estos trabajos, se optimizaron los parámetros de las redes neuronales (momento, número de capas ocultas y número de neuronas en las capas ocultas) mediante un diseño de experimentos factorial 3<sup>3</sup>. La red creada era capaz de predecir la blancura con un error del 5%, y una investigación posterior anticipó todavía mejores resultados. Se comentó que la inteligencia artificial permitiría la creación en el futuro de modelos más precisos, y así mismo la optimización de las propiedades del cartón pintado a partir de grandes históricos de datos del proceso.

Las predicciones de la blancura también han sido llevadas a cabo por Smith B.A. y Broeren L.A. en 1996. Ellos analizaron con redes neuronales el proceso de destintado de la fábrica de papel prensa *Alabama River*, situada en Claiborne, obteniendo beneficios muy importantes, como se verá más adelante. Se consideró el crear un nuevo programa basado en las redes neuronales, para el análisis de optimización. Este trabajo no se ha ubicado en el destintado, debido a que se centra totalmente en las propiedades del papel y aspectos relacionados con ellas.

Se ha realizado un control del perfil del gramaje empleando para ello redes neuronales competitivas, y un modelo de descomposición por ondas canónicas llamadas “wavelets” (Sasaki, 1997). Se describió el procedimiento seguido para desarrollar ambos modelos, y se presentó un ejemplo de cada uno de ellos. La precisión de los resultados se mostró gráficamente, sin más comparaciones explícitas entre ambos métodos.

Suojärvi M., en 1997, empleó técnicas de regresión de componentes principales y redes de tipo RBF, con datos de un espectro de reflexión. La estimación de las redes neuronales fue algo mejor que la de las regresiones, pero no fue satisfactoria, probablemente debido al pequeño tamaño del grupo de datos experimentales empleados. Por tanto, este trabajo presenta una gran diferencia en su conclusión respecto a la inmensa mayoría, que obtienen habitualmente resultados exitosos. De todas formas, el autor deja una puerta abierta, debido a las ventajas experimentadas del empleo de estas técnicas de modelado, ya que representan un método continuo y rápido.

El programa “*BCTEngine*” se ha empleado para predecir la calidad de las cajas de cartón corrugado (Joeressen, 2001). Se compararon las redes neuronales con la fórmula de McKee, y se obtuvieron ahorros significativos con el programa, como se verá más adelante.

El éxito del empleo de las redes neuronales para la estimación del índice Kappa ha sido mostrado en varios trabajos (por ejemplo, véase la sección de digestores). Haataja y col., en 1997, presentaron el analizador de la lejía de cocción, en el que las redes neuronales se emplearon para construir un modelo que tuviese en cuenta las relaciones existentes entre las medidas de entrada y de salida. Los resultados, incluyendo la estimación del índice Kappa, fueron alentadores.

La curvatura del papel ha sido predicha en varios trabajos, empleado perceptrones multicapa y especificando los intervalos de confianza (Edwards y col., 1999a; Edwards y col., 1999b). Los autores comentaron que las redes se debían emplear con presencia de una cantidad concreta, aunque limitada, de datos erróneos (Edwards y col., 1999b). Sin embargo, la experiencia en nuestro grupo de investigación señala que en el entrenamiento del modelo, poniendo en juego su robustez, han de preprocesarse los datos, filtrando en la medida de lo posible aquellos erróneos, con el objetivo de que no se aprendan patrones derivados de malos funcionamientos, que podrían confundir las predicciones. Edwards y col. publicaron otro artículo similar, en el que se empleó un preproceso de datos consistente en la eliminación de datos lejanos en el pasado, y se predijo la curvatura del papel de forma satisfactoria. El mismo grupo ha publicado trabajos relacionados con las aplicaciones de las redes neuronales en la industria papelera en general (Edwards y Murray, 2001), en el que se obtuvieron conclusiones generales sobre el modelado de la curvatura del papel, al aplicar la “*Fusión Bayesiana*”, con el fin de minimizar el riesgo durante el modelado (Edwards y col.,

2002). Los autores obtuvieron buenos resultados al combinar varias redes neuronales.

También se ha realizado con redes neuronales la predicción de la suavidad del papel tisú (Sarimveis y Retsina, 2000). Los resultados satisfactorios hicieron pensar a los autores el continuar aplicando las redes neuronales para proporcionar información sobre el proceso, como las variables que más influencia presentan sobre la calidad del producto, aquellas no significativas debido a su pequeño efecto sobre las salidas del proceso, y el tiempo muerto para cada par de variables de entrada/salida. Con los modelos se podría realizar una simulación fuera de línea, para la realización de distintos escenarios. Esto puede conducir a la selección de los mejores puntos de consigna posibles para las variables de entrada y, por tanto, a la optimización del proceso.

##### **4.1.2.15. Otras aplicaciones**

Existen también publicaciones que tratan del empleo de las redes neuronales, sin especificar ninguna sección concreta, en las que se cubren aspectos diversos del empleo de las redes neuronales en la industria pastero-papelera, el preproceso y proceso posterior de datos o el empleo de redes neuronales en paralelo (Beaverstock y Hinson, 1993). En este trabajo se señalaron áreas donde las redes se diferencian de otras aplicaciones, como la recolección de datos, su clasificación, y las características necesarias del sistema de programación. Se comentó asimismo la ventaja del empleo del análisis multivariable, con técnicas como el análisis de componentes principales, combinado con redes neuronales con algoritmos de retropropagación y Levenberg-Marquardt (Bissesur y col., 1999). Concluyeron que resulta esencial un modelo estadístico multivariable robusto para la monitorización de la eficiencia. El análisis de componentes principales ayudó a evitar trabajar con datos correlacionados. Se presentaron también las ya citadas “wavelets”.

Los perceptrones multicapa de una capa oculta, las redes neuronales difusas, la media móvil no lineal y la media móvil no lineal auto-regresiva de salidas originadas externamente (método NARMAX), se han empleado para predecir los fenómenos de corrosión en una fábrica de pasta y papel (Bucolo y col., 2002). Los autores recomendaron el empleo de modelos globales auto-regresivos y simples. Se proporcionó la predicción del potencial de corrosión del acero AISI 316L,

consiguiendo una gran mejora al emplear la técnica neuronal-difusa. Los sensores se pasaron a emplear menos frecuentemente, y se tuvo un control predictivo de la calidad de la pasta, que redujo los costes en la compañía.

El programa WinMOPS de toma y análisis de datos en planta y su estructura fueron descritos en otra publicación (Farzadeh y col., 1997). Los autores introdujeron el empleo de las redes neuronales en el contexto de un sistema que emplease el programa WinMOPS. Se explicó la comunicación entre distintas secciones al implementar el sistema en fábrica.

El programa KCL-Wedge ha sido presentado con su esquema de tratamiento de datos (Kajanto, 2002). Este sistema de análisis de procesos por ordenador se construyó con la idea de manejar cantidades enormes de datos con una interfaz de herramientas fáciles de emplear. Se describieron las herramientas de análisis de datos, así como la forma de mejorar la fiabilidad de los datos, cómo incluir sensores virtuales y cómo corregir problemas.

Fadum O., en 1993, publicó una introducción a la inteligencia artificial, describiendo la lógica difusa y las redes neuronales, y dando referencias acerca del estatus de la industria y las tendencias en el futuro. Se esperaba la unión de las redes neuronales y la lógica difusa en trabajos futuros, y que estos métodos continuarían madurando, si bien dichos trabajos no se han publicado. Harvey y Harvey, en 1998, describieron también el empleo combinado de diversas técnicas. Para el control de sistemas en línea, se concluye que es útil el tener modelos dinámicos que pueden emplearse para la exploración de escenarios tipo “qué ocurre-si”. El control en línea, el aviso en línea y la investigación fueron citados como las principales aplicaciones industriales.

La metodología en la investigación ha sido también analizada con redes neuronales, para predecir las propiedades del papel (Budaraju, 2001). El autor sugirió que con una metodología adecuada se podían construir modelos precisos en tiempo real durante la formación de la bobina.

Otro trabajo más reciente (Kangas P. y col., 2012) revisa el modelado termodinámico de las suspensiones de pasta, dando pequeñas pinceladas del empleo de redes neuronales como apoyo a la teoría establecida.

Otra comparación entre diferentes técnicas de modelado, destacando los resultados obtenidos con las redes neuronales, ha sido llevada a cabo por Ingman en el año 2000. Citó como ejemplo la optimización de la mezcla de materias primas, en la que se esperaba complementar en el futuro el sistema automático de comprobación del muestreo, con un modelo neuronal que rellenaría los espacios vacíos en la base de datos.

Podkulski D.E. en 1997, James R. en 2000 y Rodden G. en 2001 también publicaron descripciones de diferentes técnicas de modelado, incluyendo las redes neuronales. Éstas fueron citadas como una de las últimas técnicas para medir propiedades y componentes de corrientes de proceso (Podkulski, 1997). Se comentó el hecho obvio, pero a veces olvidado, de que los modelos, en este caso con redes neuronales, no pueden ser más precisos que los análisis empleados como referencia, y se formuló una queja de la bibliografía, comentando que no se había realizado un tratamiento adecuado de los resultados de referencia, relativizándolos con las prestaciones de las redes neuronales. En un análisis de tendencias de la industria pastero-papelera, incluyendo el mercado chino, las redes neuronales fueron citadas dentro de los métodos de modelado (James, 2000). Otra publicación relativa al ofrecimiento de nuevos métodos para hacer de la fábrica de papel un lugar más seguro hizo una pequeña referencia a las redes neuronales (Rodden, 2001).

Se ha llevado a cabo una revisión del empleo de sensores basados en redes neuronales para aplicaciones de producción (Keller y col., 1994). Más que una revisión exhaustiva de publicaciones, el trabajo se refiere a un ejemplo de aplicación, compuesto por una red neuronal con algoritmo de retropropagación con factor de aprendizaje constante y momento, una capa oculta de seis neuronas y 15000 iteraciones. Se transformaron las señales de diferentes sensores ópticos, con el fin de clasificar los aditivos químicos (Acetona, limpiacristales, cemento de goma y vinagre). La ventaja de las redes neuronales sobre otras técnicas convencionales analíticas se basaba en la compacidad, portabilidad, la capacidad de realizar los análisis en línea y la automatización. Se propuso una comparación futura entre las redes neuronales y técnicas más convencionales, explorando otros modelos de redes y evolucionando los prototipos preliminares.

Una aproximación genérica a los sensores virtuales, incluyendo un esquema de trabajo general y un caso práctico con resultados, fue llevada a cabo por Martin en 1997. Las redes neuronales de alimentación hacia delante se

emplearon para construir sensores virtuales, definiendo sus diversas partes. También fueron empleadas para una simulación (Zhu y col., 1996). Se propuso una forma de reducir los errores a través de la optimización de los modelos, y se concluyó que un número elevado de neuronas incrementaría la predicción del ruido, mientras que con una menor cantidad de ellas, se mejorarían las capacidades de generalización.

Recientemente se ha publicado un estudio acerca del control de anomalías en procesos industriales continuos, centrandó el ejemplo en la sección de evaporación de una planta de pasta química (de Almeida G.M. y Park S.W., 2013). Debido a la dinámica particular de esta sección, se ha empleado una red neuronal con función de retraso temporal, con resultados satisfactorios.

#### **4.1.2.16. Tendencias / Economía**

En una entrevista en la revista *PIMA's Papermaker*, se analizaron las tendencias en la automatización de procesos (Ryan, 1998). La entrevista fue una mesa redonda entre los siguientes participantes: David Baker, Jim Bourque, Brad Garnett, Wayne hopson, Antti Kaunonen, Robert Kirsch, Nils Leffler, Tim Mores y Charlie Rowland, la mayoría de los cuales pertenecían a puestos relacionados con la sección de mercadotecnia en diferentes compañías. Jim Bourque, de la empresa *Bailey Controls Co.* señaló a las redes neuronales como el principal avance durante aquellos años.

Se han empleado mapas autoorganizados para evaluar las tendencias económicas en el sector pastero-papelero. Se analizaron los ciclos económicos a nivel internacional (Lansiluoto y col., 2002). Los países vecinos mostraron tener similitudes en sus ciclos de negocio. Se discutieron algunos aspectos relacionados con la distancia entre países, situaciones de "shock" específicas o la crisis asiática. La técnica de mapas autoorganizados pareció ser viable, y se describieron brevemente las limitaciones del estudio.

Speiser y col., en 1996 y Finchem, en 1998, llevaron a cabo el pronóstico de precios mediante redes neuronales, así como la interpretación de los resultados. Las redes neuronales fueron citadas como la primera técnica no lineal de modelado en el sector con alto nivel de fiabilidad (Speiser y col., 1996). Finchem empleó

modelos de pronóstico sucesivos y entrenados individualmente. Sugirió emplear el estado estacionario y turnar los modelos de predicción como un tándem.

#### **4.1.2.17. Energía**

En un trabajo relacionado con la mejora de la eficiencia energética, se explicó como minimizar el riesgo del desarrollo e implementación de sistemas inteligentes (Szladow y col., 2001). Se citaron las principales barreras para la implementación y empleo de sistemas inteligentes en la industria, que fueron: la resistencia al cambio en las organizaciones, la pobre comunicación, formación insuficiente y la percepción del riesgo asociada a las tecnologías que emplean la Inteligencia Artificial. Para evitar esta situación, se propuso un programa consistente en dos fases, siendo la primera de ellas la cuantificación de los posibles beneficios, tarea que muestran numerosas publicaciones, y que ha sido resumida en un capítulo posterior.

Un estudio completo y exhaustivo del consumo de energía eléctrica, en el que se empleaban redes neuronales para predecir las cargas eléctricas en una fábrica de papel, fue publicado por VTT (Alanen, 2000). Este amplio trabajo estudió los factores que afectaban al consumo de energía eléctrica en la línea de producción de papel, dentro de la fábrica. Los factores más influyentes, así como las cargas, fueron clasificados, y se desarrolló una metodología de pronóstico basada en las redes neuronales. Los resultados fueron considerados suficientemente precisos, y fueron mejores que los métodos empleados hasta aquel momento. Se propusieron nuevas mejoras, acompañadas de un procedimiento de implementación, dándole gran importancia al sistema ampliamente integrado de información y gestión presente en la fábrica, con el fin de automatizar completamente la herramienta desarrollada.

#### **4.1.2.18. Trabajos matemáticos**

Algunos artículos presentan referencias muy breves a la aplicación en la fabricación de papel, y sin embargo se centran en diferentes aproximaciones matemáticas al problema. Por ejemplo, se ha publicado un trabajo consistente en la explicación de cómo interpretar los pesos internos de una red al entrenarla con algoritmo de retropropagación (Chitra, 1993). Otro trabajo de características

similares, pero sin referencias a la industria del papel, fue publicado por Tchaban y col., en 1998.

Algunas de las publicaciones revisadas contienen en mayor o menor medida revisiones bibliográficas. En el artículo "Review, developments and pulp and paper applications of data reduction with neural networks" (Karrila y Rezak, 2002), que se centró en las técnicas de reducción del número de datos y en el que, por tanto, las referencias bibliográficas eran principalmente matemáticas, se puede encontrar una buena revisión de artículos basados en el empleo de redes neuronales en la industria papelera. Se incluyó como ejemplo en esta revisión la distribución del tamaño de las burbujas en las suspensiones de pasta.

Existe una gran multitud de artículos que tratan de diversos aspectos matemáticos al desarrollar las redes neuronales, pero que no se aplican directamente en la industria pastero-papelera y, por tanto, no han sido incluidos en esta revisión. De todas formas, fuentes como las publicaciones *Neural Computing and Applications*, *IIE Transactions*, *Computers and Chemical Engineering*, etc. proporcionan un conocimiento muy profundo de diferentes aspectos en el desarrollo de las redes neuronales.

Lanouette R. y col. y Sarimveis H. y col. han publicado varios trabajos al respecto, pero aplicados en la industria pastero-papelera (Lanouette y col., 1997; Lanouette y col., 1998; Sarimveis y Retsina, 2000; Sarimveis y col., 2002; Thibault y col., 2003). Los mismos autores presentan otros artículos con temática principalmente matemática, como la comparación de diferentes estructuras de redes neuronales en pila para alcanzar elevada robustez con grupos pequeños de datos experimentales, advirtiendo que la ortogonalidad proporcionada por un diseño D-Optimal mejoró las prestaciones en general al crear redes neuronales con datos seleccionados al azar (Lanouette y col., 1999). El desarrollo de un algoritmo para crear redes tipo RBF dinámicas, basándose en algoritmos genéticos, fue otra sugerencia encontrada en la bibliografía, en un trabajo eminentemente matemático con un ejemplo de predicción del índice Kappa (Sarimveis y col., 2004).

Nuestro Grupo de Investigación de Celulosa y Papel, en colaboración con la Universidad de Tampere (Konkarikoski K. y Alonso A., 2008), publicamos un estudio acerca de la verificación continua de sensores online basada en la detección de anomalías en los parámetros, empleando el control estadístico de procesos

mediante distancia de Mahalanobis. Este sistema dinámico de validación sirve para procesos lineales gaussianos y de tipo Ornstein-Uhlenbeck.

#### **4.1.2.19. Alternativas**

Un caso en el que se ha propuesto una alternativa a las redes neuronales con éxito es el trabajo publicado por Chinnam en 2002, en el que la técnica llamada “*Support Vector Machines*” (SVM) fue presentada, comparando sus resultados con los de trabajos previos en el mismo campo (la mejora del control estadístico de procesos o SPC con redes de tipo RBF, propuesta por Cook y Chiu, en 1998). Se había considerado previamente que el modelado con redes del tipo RBF suponía una mejora sustancial sobre los gráficos de control estadístico del proceso, tomados cada cierto tiempo, con el fin de ver datos correlacionados. La aplicación fue el reconocimiento de cambios, mediante el análisis del índice de clasificación de las condiciones de operación. Los resultados al aplicar el método SVM fueron mejores en algunos casos, y se tomó esto como un punto de partida para la comparación de ambos métodos más en detalle, aplicando para cada uno de ellos el preproceso de datos y las técnicas de modelado.

#### **4.1.3. Beneficios económicos publicados de las redes más utilizadas**

En general, casi todas las aplicaciones publicadas han supuesto beneficios de diversa índole a los fabricantes de papel, ya que mejoran el control del proceso de fabricación de papel en general, o de distintas etapas, o proporcionan nuevas alternativas para la predicción de diferentes parámetros de proceso.

Más allá de las mejoras comentadas, en algunas publicaciones se han expuesto de forma explícita los beneficios económicos derivados de la aplicación de las redes neuronales.

- La optimización del proceso mediante predicciones de la blancura permitió ahorrar 289,000 US\$/año en costes de aditivos químicos del pulpeo (Broeren y Smith, 1996). La implementación por parte de los mismos autores de las redes neuronales, en un estudio similar, permitió una reducción de costes anual total de 138,000 US\$ (Smith y Broeren, 1996).
- El control del horno de cal dio como resultado un ahorro del 7% en el consumo de energía específica de calentamiento, debido a la disminución

del exceso de aire para el quemado, y la consecuente reducción de las pérdidas de calor (Järvensivu y col., 2001).

- Al predecir los valores de compresión en cajas de cartón corrugado, se ahorró un 5% de los costes totales (Joeressen, 2001).
- La predicción de la demanda biológica de oxígeno permitió ahorrar un millón de dólares en el año 1998 (Masmoudi, 1999).
- El diagnóstico de roturas mediante redes neuronales y análisis de componentes principales (Miyanishi y Shimada, 1998), desembocó en varias ventajas: la retención total y de cenizas en el primer paso mejoraron un 3% y un 4% respectivamente, la generación de lodos en el clarificador de efluentes se redujo un 1%, el consumo de alumbre decreció y, como resumen, la reducción de costes total anual se estimó en un millón de dólares.
- La aplicación de la lógica difusa y las redes neuronales para el control del índice Kappa resultó en una reducción de las desviaciones de este índice en un 25% (Pulkkinen y col., 1997).
- Stapley y col., en 1997, experimentaron varios beneficios al emplear las redes neuronales en el final de la parte húmeda. En unas pruebas de confirmación, se redujeron los costes de aditivos químicos en un 32% (lo que significa un ahorro anual de 800,000 US\$) y la producción se incrementó un 6% (lo que representa 1,300,000 US\$/año, con una contribución de 100 US\$/Tn). La blancura incrementó un 10% y esto permitió una reducción del consumo de aditivos químicos de blanqueo para la pasta termomecánica (lo cual supuso unos ahorros adicionales entre 100,000 y 200,000 US\$/año).
- Finalmente, el desarrollo del sensor virtual para el control de blancura en la etapa del dióxido de cloro (Vaughan y col., 1999), ha reducido la frecuencia de lotes fuera de especificaciones en un 13%, la variabilidad de la blancura en un 50%, e incluso se ha reducido la cantidad empleada de dióxido de cloro en un 33%.

Las redes neuronales se han aplicado con éxito, como puede observarse en los beneficios económicos, en prácticamente todas las etapas de la producción de papel, con gran variedad de objetivos.

Las redes de alimentación hacia delante, denominadas también perceptrones multicapa, son las más empleadas en las publicaciones revisadas.

Las redes de una capa oculta son las más empleadas, y proporcionan resultados robustos, dependiendo de la sección estudiada y el procedimiento de desarrollo de los modelos.

No se han encontrado reglas específicas para el cálculo del número de neuronas en las capas ocultas. El método de prueba-error sigue siendo el más utilizado.

La ecuación 12 ha sido propuesta para el cálculo de la cantidad mínima aceptable de datos. Aparte de esta ecuación, no se han encontrado más reglas generales para calcular, por ejemplo, la cantidad óptima de datos o su distribución en el tiempo.

El preprocesamiento de los datos ha sido considerado crucial en muchos de los artículos revisados. Se han visto técnicas muy diversas, pero se echa en falta una metodología general, aplicable en estos casos.

Por tanto, en esta tesis doctoral se va a avanzar un paso más con respecto al estado del arte, puesto que, por una parte, se van a aplicar por primera vez las técnicas de modelado descritas con datos procedentes del sensor de reflexión de haz enfocado (FBRM) para predecir la calidad del producto. También resulta novedoso el empleo del sensor FBRM en la parte húmeda de la máquina de papel con estos fines y, por último, se define una metodología de trabajo aplicable a problemas de índole industrial que se ha echado de menos en la bibliografía, y podría ser un primer paso hacia la definición de unos estándares de modelado que garanticen la máxima calidad posible de los resultados.

#### **4.2. HERRAMIENTAS PARA EL DESARROLLO DE REDES NEURONALES**

Dentro de las posibilidades existentes para el desarrollo de este tipo de modelos, se encuentran los lenguajes de programación clásicos, abiertos a cualquier algoritmo o desarrollo, y otros programas que ya implementan dichos algoritmos para su aplicación por parte del usuario. A continuación se enumerar muchos de ellos.

En las páginas web de cada producto se puede encontrar una descripción breve de cada uno de los programas existentes en el mercado, con el factor común de servir de herramientas para el desarrollo de redes neuronales.

#### **Programas de distribución gratuita**

- The ART Gallery
- Aspirin/Migraines
- AUSIM
- BackBrain
- Backprop-1.4
- Basis of AI
- Binary Hopfield Net with free Java source
- bps
- Brain Neural Network Simulator
- CADSIM Plus
- Cascade Correlation Simulator
- Con-x
- DartNet
- FastICA
- FuNeGen
- Fuzzy ARTmap
- Hyperplane Animator
- LVQ PAK
- Mactivation
- Matrix Backpropagation
- Multi-Module Neural Computing Environment - MUME
- Negative feedback neural net - JavaScript
- Neocognitron
- Net II
- NETS - Network Execution and Training Simulator
- Neural Networks at your Fingertips
- Neural Simulation Language Version - NSL
- NeuralShell
- NeuDL
- NeurDS
- Neurfuzz
- NeuroForecaster/GA

- NevProp
- NICO Artificial Neural Network Toolkit
- NNMODEL
- nn/xnn
- NNCTRL
- NNSYSID
- PDP Software
- PDP++ Software
- Pittnet
- PlaNet
- Pygmalion
- QwikNet
- R
- Rochester Connectionist Simulator (RCS)
- Roxanne
- SESAME - Software Environment for the Simulation of Adaptive Modular Systems
- SOM PAK
- SOM Toolbox for Matlab
- SpiderWeb Neural Network Library
- Spike and Neuralog
- Stuttgart Neural Network Simulator (SNNS)
- SynWorks
- Time Delay Neural Network - TDNN
- tlearn
- UCLA-SFINX
- Valentino Computational Neuroscience Workbench
- VFSR - Very Fast Simulated Reannealing
- WinNN
- Xerion Simulator

#### **Software comercial**

- Adaptive Logic Network
- Attrasoftware Boltzmann Machine (ABM)
- Attrasoftware Predictor

- BioNet Simulator
- Braincel
- BrainMaker
- BrainSheet for Win95
- CATPACK
- DataEngine
- DataMining Workstation (DWM) and DWM/Marksman
- Domain Solutions' Neural Networks for Developers
- DynaMind Developer Pro
- ECANSE - Environment for Computer Aided Neural Software Engineering
- EXPO/NeuralNet
- FCM (Fuzzy Control Manager)
- FlexTools
- havBpNet:J
- havBpNet++
- havFmNet++
- IBM Modeler (Anterior SPSS Clementine)
- KnowMan Basic Suite
- MacBrain
- **Matlab: Neural Network Toolbox**
- Model 1
- Nestor Development System
- Neuframe
- Neural Bench
- Neural Connection
- Neural Net Tutor
- Neural Network Utility/2
- Neural Parts
- NeuralWorks
- NeuroClassifier
- NeuroCoM (Neuro Control Manager)
- NeuroForecaster/GENETICA
- NeuroGenetic Optimizer
- Neurogon
- NeuroLab
- NeuroLution simulation and development system
- NeuroModel®

- NeuroShell
- NeuroSolutions
- NeuroWindows
- N-Net
- NNMODEL
- Owl Neural Network
- Partek
- PathFinder
- Pattern Recognition Workbench - PRW
- PolyAnalyst
- PREVIA
- Process Insights
- Propagator
- SAS: Neural Network Add-On, o bien Enterprise Miner
- Saxon
- STATISTICA: Neural Networks
- Thinks and Thinks Pro
- TNs2Server
- Trajan
- Viscovery SOMine
- WinBrain

#### **Herramientas de hardware para el uso de redes neuronales**

Existen también elementos de hardware y aplicaciones para estos elementos desarrollados de forma comercial, los cuales se enumeran a continuación.

- Adaptive Solutions Neural Network Tools
- CNAPS Server
- Hughes M1718
- Nestor Ni1000 Recognition Accelerator
- NeuralBoard
- NeuroLution PCI Board
- NeuroMatrix(R) NM6403 Neuroprocessor
- NM1 NeuroMatrix(R) PCI Board
- NNP
- SAND neurochip

- Siemens MA-16
- SYNAPSE3\*PC
- ZISC36

El elevado número de programas y placas existentes hacen ver, una vez más, el actual desarrollo de este tipo de herramientas para la creación de modelos matemáticos.

### 4.3. HERRAMIENTAS PARA LA SIMULACIÓN DE PROCESOS

Debido a la inexistencia de simulaciones específicas para la industria del fibrocemento, y debido a la similitud de los procesos con la industria papelera, se ha optado por recurrir a un simulador propio de la industria del papel, que sirva de apoyo en las investigaciones realizadas en la industria del fibrocemento.

El campo de los simuladores presenta varios programas, con la característica de no ser ninguno de ellos el mejor genéricamente hablando, sino que, dependiendo del tipo de industria estudiada, hay unos más desarrollados y otros que no lo están tanto. En el mercado existen numerosas alternativas para la simulación de procesos:

- **APROS:** Un entorno de simulación dinámico, desarrollado por VTT (Finlandia). Similar a Simconx o IDEAS en su empleo.
- **Aspen Plus – Hysys:** Programa especializado en la industria del petróleo, que presenta una interfaz gráfica del mismo tipo que el explorador de Windows. Sus bloques son programables en Fortran, aunque los que se presentan comercializados poseen código de programación cerrado. El punto fuerte de este programa estriba en la gran base de datos de diferentes compuestos químicos y de sus propiedades, tanto en solitario como mezclados, lo cual se traduce en una gran capacidad para realizar cálculos termodinámicos y de diseño muy detallados. Requiere gran cantidad de datos antes de comenzar la simulación, debido al alto grado de detalle que presenta. Es un programa muy utilizado, principalmente en la industria petroquímica.
- **BALAS:** Parecido a WinGEMS, presenta las aplicaciones generales de un simulador. Desarrollado por VTT.

- **CadSim Plus:** Distribuido por Aurel Systems, este programa resulta otro simulador genérico con interfaz de usuario sencilla para resolver balances y simulaciones de cierta entidad.
- **Extend:** Cabe destacar de este entorno de simulación, utilizado en las simulaciones realizadas en la presente tesis, que presenta un sistema de resolución de ecuaciones secuencial de tiempo finito, lo cual resulta una ventaja respecto al tiempo de cálculo y la facilidad de convergencia, pero que en algunos casos puede proporcionar resultados incoherentes, debido a los escalones matemáticos provocados al resolver la simulación. Para ello, resulta conveniente añadir al código de programación correcciones para evitar divisiones por cero, o efectos no deseados en la apertura programada de válvulas, entre otros ejemplos.
- **G2:** Este producto de la compañía Gensym, fue uno de los primeros en emplearse para simulaciones dinámicas y como sistema experto. Presenta una interfaz donde se pueden programar objetos o bloques en un lenguaje propio de alto nivel. Tiene capacidad de comunicarse con sistemas de control distribuido.
- **Honeywell:** Al comienzo este programa se empleaba en combinación con el anterior, y sus principales aplicaciones han sido descritas para procesos relacionados con el petróleo, con el manejo de gases y plantas químicas. No se dispone de mucha información sobre este producto, pero probablemente ha de ser parecido a Simconx, debido entre otros factores a sus comienzos comunes. (Dahlquist y col., 2004)
- **IPSEPro:** Empleado principalmente en centrales energéticas, este simulador es estático, basado en la creación de bloques, programables mediante código similar al C++. No se dispone de más información acerca de sus detalles.
- **MASSBAL:** Simulador estático útil para balances de masa.
- **Modellica y gPROMS:** Estos programas pueden ser considerados como alternativas a Extend, debido a que internamente presentan dos lenguajes de alto nivel distintos al lenguaje MoDL empleado en Extend, pero con el objetivo de crear simulaciones programadas en bloques. Presentan un sistema simultáneo de resolución de sistemas de ecuaciones, lo cual en algunos casos puede ralentizar de forma impredecible la simulación.

- **PaperMac, PulpMac, FlowMac e IDEAS, en entorno EXTEND:** Al igual que el programa seleccionado para realizar las simulaciones, existen otros productos bajo el entorno de Extend, como programa base para albergar las simulaciones. PaperMac y PulpMac son productos de la compañía PaperMacAB, más destinados al diseño de equipos y simulación de propiedades de pasta y papel. FlowMac es el producto destinado a simular los balances másico y energético. IDEAS fue desarrollado con el mismo programa base Extend, creando librerías específicas para la industria papelera, en este caso con código cerrado. Su empleo resulta similar al de FlowMac, con algo más de detalle en las bases de datos de componentes químicos, pero menos capacidades gráficas de animación que éste.
- **PROSIM:** Desarrollado en la universidad de Helsinki, este programa se emplea para fines educativos, principalmente en el diseño de centrales energéticas. Su mayor limitación es la interfaz gráfica, poco desarrollada.
- **Simconx:** Trabaja con bloques programables en Fortran, sobre la interfaz gráfica de G2. Este producto, de la compañía ABB, se presenta para varias industrias. De 200 simuladores que se han distribuido con este producto, 14 han sido destinados a la industria papelera (Dahlquist y col., 2004).
- **Simulink (Matlab):** Simulador matemático para todo tipo de problemas, con la versatilidad que le proporciona la base de Matlab. En cambio, no posee bloques específicos para la industria del papel, con lo cual han de ser programados por el usuario, incrementándose el tiempo de elaboración de las simulaciones. Por otra parte, presenta gran variedad de opciones para la resolución del sistema final de ecuaciones. Motores del tipo “ODExx” permiten la resolución de la simulación mediante la aplicación de ecuaciones diferenciales, a la vez que existen sistemas de tiempo finito.
- **WinGems:** Programa especializado en la industria del papel, y de gran difusión en la misma (Informe encuesta COST E36). Presenta la posibilidad de trabajar con reacciones químicas. Requiere para una buena simulación algunos datos de diseño de los equipos. Trabaja con densidades y flujos másicos. Gran flexibilidad para adaptar secciones de proceso a la simulación mediante bloques de

partición y mezcla de corrientes de proceso, llamados “Split” y “Mix”. El código de programación en los bloques disponibles con la licencia del programa es cerrado. Se pueden programar bloques nuevos en Fortran. El trabajo con multicomponente resulta sencillo. Es destacable su facilidad de manejo para el usuario.

- **Otros programas:** Existen más programas para soluciones muy variadas, tanto de simulación de propiedades de la pasta (KCL-Pakka), como para la creación de bases de datos unidas a un sistema de control distribuido (DCS), así como la inclusión de estos datos en simulaciones o diagramas de proceso (KCL-Propose). No deben confundirse estos programas con los de análisis de datos, como WinMOPS o KCL-Wedge, los cuales presentan otro tipo de herramientas no destinadas a la simulación en sí.

#### **Programas de libre acceso**

- **Design II para Windows:** Programa de simulación genérico, bastante limitado en cuanto a resultados y de código cerrado. De poca difusión. Programación poco clara.

#### **4.4. PROGRAMAS PARA EL ANÁLISIS Y PROCESAMIENTO DE DATOS**

Existen multitud de programas que permiten operar con los datos obtenidos de fábrica, con el fin de crear un entorno óptimo para el posterior modelado mediante redes neuronales o cualquier otro método alternativo.

En este caso presentar cada programa de análisis numérico resultaría abrumador debido a la infinidad de alternativas existentes. Simplemente se puede destacar que cada sistema operativo tiene su propio conjunto de herramientas para el manejo de datos numéricos, y que incluso se pueden utilizar a tal efecto archivos de texto con operaciones programadas en cualquier lenguaje de uso común. La selección del sistema apropiado deberá siempre tener en cuenta la compatibilidad con los sistemas empleados en cada fábrica.

## 5. MATERIALES Y MÉTODOS

### 5.1. MATERIALES

Dentro de los materiales empleados en esta tesis doctoral, se incluyen las fábricas en las que se ha desarrollado la investigación y las materias primas empleadas: papel y fibrocemento.

#### 5.1.1. Fábricas

Como se ha comentado previamente en el apartado de procesos industriales, las fábricas en las que se ha desarrollado el trabajo son:

- En el caso del fibrocemento, se ha trabajado principalmente en la línea número 3 de la fábrica de Uralita situada en Valladolid, que posteriormente fue vendida a otros propietarios y trasladada. Dicha planta trabajaba principalmente diferentes perfiles de placas para tejados, con la adición de PVA como fibra inorgánica.
- En el caso del papel, la línea de producción PM 61 de la fábrica de Holmen Paper Madrid (HPM), situada en la calle del papel del Municipio Madrileño de Fuenlabrada. Esta planta se adapta a la producción de diferentes tipos de papel a partir de pasta reciclada, pero el de más demanda, que es objeto de estudio en la presente tesis, es el papel prensa, que se describe a continuación.

#### 5.1.2. Materias Primas

El fibrocemento, al tratarse de placas destinadas mayoritariamente a tejados, se emplea una composición con las siguientes materias primas:

- Cemento: Habitualmente cemento Portland de tipo II, con una concentración en las corrientes del proceso que puede llegar a 300 g/l.
- Celulosa: Presente en concentraciones de hasta 11 g/l.
- Sílice Amorfa: Aditivo para mejorar las propiedades del producto que puede llegar a alcanzar los 22 g/l.
- PVA: Fibras de alcohol polivinílico, que llegan hasta los 6 g/l.

- Pigmento: Eminentemente pigmento color teja, rojo oscuro, con concentraciones de hasta 4 g/l.
- Floculante, añadido en la corriente previa a los cilindros de formación, es el componente que permite aglutinar al resto en capas mediante cilindros de vacío. La concentración máxima estudiada llega a 34 mg/l.

En cuanto al papel prensa, fabricado en la planta de HPM, está fabricado a base de papel recuperado, previamente tratado. Puede ser blanco o ligeramente coloreado, dependiendo de la demanda, y los gramajes estudiados y mayoritariamente producidos oscilan entre 42.5 y 48.8 g/m<sup>2</sup>. No se entra en el detalle de la composición y formulación de los aditivos empleados, que variarán en función de las propiedades de la pasta reciclada que se esté empleando en cada momento.

## 5.2. EQUIPOS Y SOFTWARE

Los equipos empleados para realizar los estudios de investigación en esta tesis doctoral son, por una parte, programas informáticos, y por otra, el sensor FBRM de Lasentec®, como herramienta para estudiar el proceso de floculación de las suspensiones de fibrocemento y de pasta de papel.

Los programas informáticos se usan con varias finalidades. Algunos de ellos se emplean como si fuesen un laboratorio para obtener modelos matemáticos y analizar sus resultados, dentro de la búsqueda de correlaciones entre diferentes medidas tomadas en planta con la sonda FBRM. El que se emplea en la tesis con este fin es Matlab®, por razones que se detallarán más adelante.

Asimismo, otra tarea de la tesis, relacionada con la anterior, consiste en realizar la simulación dinámica de plantas de producción de papel y fibrocemento, para lo cual se emplea el programa FlowMac, una aplicación para la industria del papel con subrutinas incluidas en el programa base Extend, el cual se describirá posteriormente.

Al emplearse programas informáticos, se requiere utilizar ordenadores personales que puedan soportar sus entornos, convirtiéndose éstos en el “laboratorio virtual” del investigador. El método de trabajo seguido con cada

programa consistirá en la planificación de los “experimentos a realizar” y la posterior ejecución de los mismos mediante subrutinas creadas por el usuario, o añadiendo datos o modelos a programas ya existentes. Por último, una vez obtenidos los resultados, mediante otras subrutinas diferentes, serán tratados para realizar un análisis completo que optimice el trabajo posterior a realizar, y permita obtener conclusiones claras acerca de las tareas realizadas.

Un punto importante dentro de este tipo de trabajo consiste en la validación de los modelos y programas creados, comparando los resultados con datos experimentales obtenidos bien en planta bien en laboratorio. El objetivo, por tanto, será la minimización del error de validación, que redundará en un modelo más exacto.

El concepto de precisión pierde sentido cuando se manejan programas basados en matemáticas que, a una misma entrada, darán una misma salida, sin ningún tipo de dispersión. La dispersión tendrá que considerarse a través del error de validación del modelo y del error experimental de los datos de entrada y de salida de los que se disponga.

En este capítulo se describen los programas empleados y, posteriormente, se muestran los métodos seguidos, bien en forma de subrutinas, diagramas de bloques o descripción de las secuencias de operación. En cuanto al ordenador empleado, se describirá indicando sus ventajas y sus limitaciones.

### **5.2.1. Sensor de floculación**

La sonda FBRM de Lasentec® (Mettler-Toledo) se ha utilizado como sensor de floculación en laboratorio y en planta para realizar el seguimiento del proceso de floculación mediante la evolución del tamaño de cuerda de la partículas en suspensión.

La longitud de cuerda es el camino recorrido por un haz láser de reflexión de haz enfocado durante el cual la partícula refleja sus rayos, como se observa en la figura 5.1.




Figura 5.1 - Método de medida de longitudes de cuerda de la sonda FBRM.


Por tanto, en cada medida no se tiene en cuenta la forma de la partícula, sino el camino más corto trazado sobre ella por el láser. Al poderse medir cientos de miles de longitudes de cuerda en un segundo, la medida resultante tiene gran robustez, y comparada con patrones, puede incluso dar una idea del tipo de partículas que allí se tienen.

Estas medidas ya se han utilizado para estudiar el efecto de la adición de floculantes sobre suspensiones de partículas en trabajos anteriores del mismo Grupo de Investigación. Ahora se pretende, a partir de ellas, predecir las propiedades finales que van a presentar los dos productos estudiados: el fibrocemento y el papel.

Existen dos tipos de medidores comerciales (figura 5.2): uno para laboratorio y otro más robusto y manejable para instalación en planta, y ambos pueden ser introducidos tanto en tuberías como en depósitos. Lo único que varía es la morfología de la sonda, ya que la unidad central es similar en ambos casos. La sonda está acoplada al software que recoge las señales de respuesta del láser, y que graba los datos en un ordenador. El posterior manejo de datos, con empleo de visualizaciones basadas en parámetros estadísticos, resulta sencillo, ya que además cuenta con una útil herramienta de exportación a formato de archivo de hoja de datos del programa Excel de Microsoft, desde el cual, una vez tratados los datos necesarios, se pueden realizar operaciones y representaciones con sencillez.



Figura 5.2 - Medidor FBRM de Lasentec® en laboratorio (encima) y en fábrica (continuación debajo).



(Figura 5.2 - Continuación)

El equipo se compone de:

- Sonda: elemento que se introduce en la suspensión, que consta de un sistema giratorio para que el láser describa una trayectoria circular (figura 5.3). Las distintas vistas que se recogen en la figura desvelan el funcionamiento de la sonda. El láser gira a elevada velocidad, recogiendo las reflexiones que producen las partículas de la suspensión, llegando a medir cientos de miles de cuentas por segundo. Cada partícula medida es una cuenta, y cada cuenta lleva asociada una longitud de cuerda, con lo que se tiene una distribución continua del tamaño de partículas. No obstante, debido a la cantidad de datos a almacenar, se establecen canales con intervalos de tamaño de partícula. El software de Lasentec trabaja con 90 canales, y permite reducir, tratar y exportar los datos de cada canal.
- Unidad Central: es donde se genera el rayo láser que, transportado por fibra óptica, será interpretado para dar una medida que se envíe al ordenador de usuario.
- Software de adquisición, revisión y análisis de datos.




Figura 5.3 - Esquema de la sonda FBRM, con sus componentes y detalle del funcionamiento.

El rayo láser realiza un barrido en el cual puede medir hasta un millón de partículas por segundo, determinando su longitud de cuerda (al multiplicar la velocidad de giro por la duración de la reflexión).

El medidor tiene gran capacidad para determinar tanto el número como la forma de las partículas, así como cambios en su conformación, pero en este proceso juega un importante papel el criterio del usuario, para determinar qué es lo que quiere saber y cómo quiere obtenerlo. Además se puede determinar que una forma concreta de partículas no se refleje en las medidas, mediante filtros de datos que el software permite ejecutar.

Para la interpretación y análisis de los datos se dispone de varios parámetros estadísticos en el software de Lasentec® (número de cuentas leídas en un segundo, tamaño medio de cuerda de la distribución, medias ponderadas de longitudes de cuerda, número de cuentas por intervalos de tamaño de cuerda y muchos otros parámetros).

Con el software empleado se pueden analizar 8 parámetros estadísticos simultáneamente. Los datos analizados de momento con el sensor láser en la presente investigación varían según el estudio a realizar. Por ejemplo, en la predicción de propiedades en la fabricación de fibrocemento han sido los siguientes (representan el número de cuentas por segundo o cps en el intervalo de tamaños de longitud de cuerda expuestos).

- cps 1-5  $\mu\text{m}$
- cps 5-10  $\mu\text{m}$
- cps 10-32  $\mu\text{m}$
- cps 32-50  $\mu\text{m}$
- cps 50-86  $\mu\text{m}$
- cps 86-100  $\mu\text{m}$
- cps 100-1000  $\mu\text{m}$
- cps 1-1000  $\mu\text{m}$

En las redes neuronales aplicadas a la fabricación de papel, estos intervalos han sido nuevamente optimizados.

La elección del lugar para la medida en planta del proceso de floculación es de vital importancia para la obtención de unos resultados fiables y aplicables, sin efectos indeseables que falseen las medidas.

La importancia de la localización de la sonda es máxima en los siguientes casos:

- Cuando las partículas presentan densidades extremas (muy altas o muy bajas).
- Con bajas concentraciones de sólidos.
- Cuando la disolución transportadora presenta una viscosidad baja.
- Cuando la forma de las partículas se aleja de la de una esfera.
- Cuando la distribución de tamaños de partículas indica un intervalo amplio de tamaños.
- Cuando la mediana del tamaño de partícula es elevada.

Por el contrario se permite una mayor flexibilidad en la colocación cuando se dan exactamente las situaciones contrarias.

El caso ideal de colocación de la sonda es en una tubería vertical de flujo ascendente, alejada entre 3 y 5 diámetros del último codo de tubería, para tener un flujo uniforme, no segregado, que permita una medida fiable y de calidad.

Para su instalación en tanques de mezcla perfecta hay que evitar zonas muertas, generalmente tras los tabiques deflectores. Se recomienda su ubicación en la cara de los tabiques opuesta al flujo impuesto por la agitación.

El número de canales empleados en los cálculos y su elección también tienen cierta importancia en la obtención de resultados.

### **5.2.2.Desarrollo de redes neuronales**

Para este fin se ha empleado el programa Matlab, de amplia difusión en el sector y cuya licencia está adquirida por la Universidad Complutense de Madrid, haciendo posible su empleo.

Se trata de un programa de cálculo matemático de todo tipo basado en subrutinas con un lenguaje propio de programación. Su potencia reside en el tratamiento de matrices de datos y en las representaciones gráficas, aparte de la existencia de subrutinas específicas para diferentes tareas, como por ejemplo la creación, entrenamiento y validación de redes neuronales. Estos conjuntos de órdenes reciben el nombre de “toolbox” o caja de herramientas. En la figura 5.4 se presenta la ventana principal del programa.

En este programa las órdenes se suelen dar en forma de secuencias ordenadas, que reciben el nombre de archivos de secuencia, llamados “script”. Cuando estas secuencias se guardan en un formato tal que puedan ser llamadas a su vez por otros archivos de secuencia, se les llama archivos función, o “function”.

Dichos archivos tienen ambos la extensión “m”, y se pueden editar utilizando la ventana de edición, que se puede observar en la figura 5.5. Con el manual del programa, disponible en Internet y en la ayuda del programa, se puede acceder a su manejo de forma sencilla.

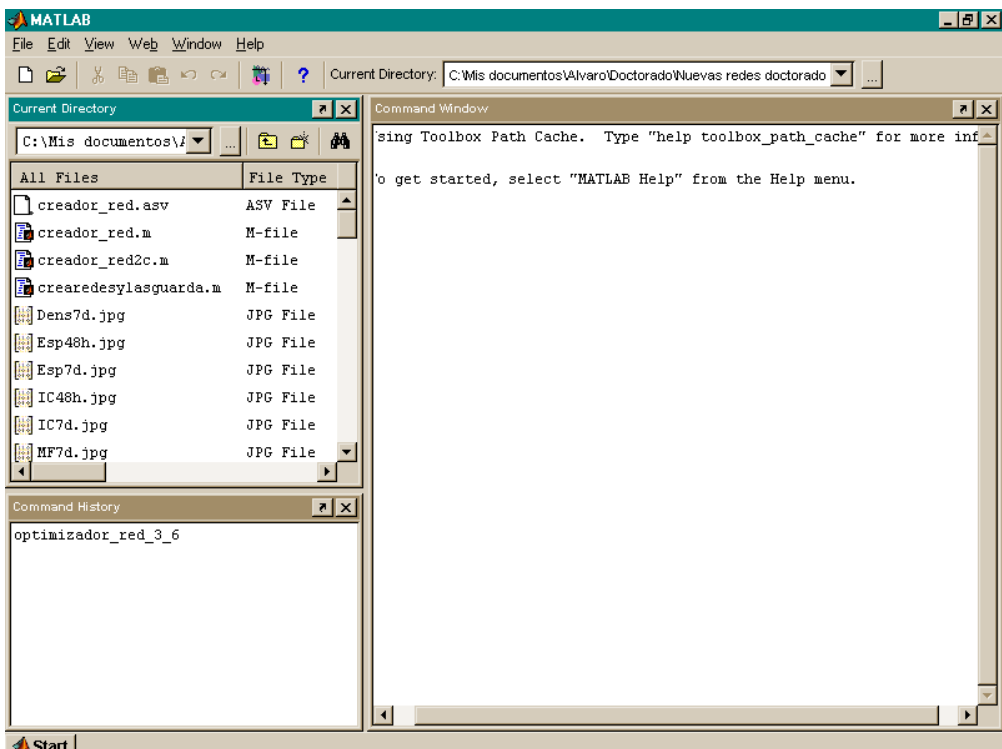
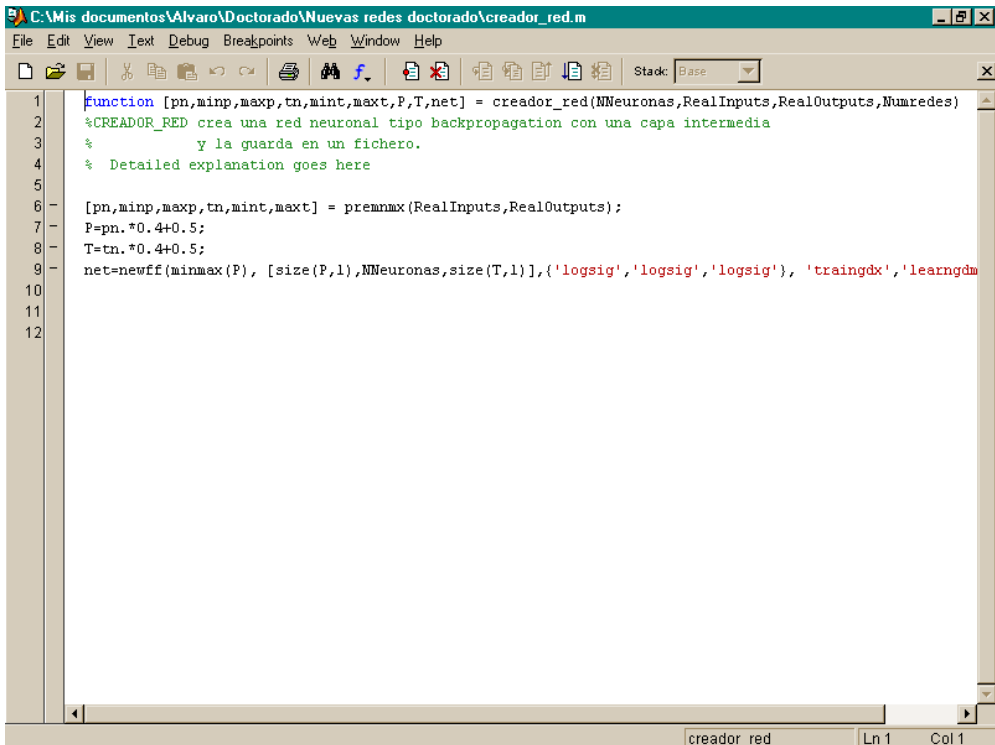


Figura 5.4 – Ventana principal de Matlab®.



```
1 function [pn,minp,maxp,tn,mint,maxt,P,T,net] = creador_red(NNeuronas,RealInputs,RealOutputs,Numredes)
2 %CREADOR_RED crea una red neuronal tipo backpropagation con una capa intermedia
3 % y la guarda en un fichero.
4 % Detailed explanation goes here
5
6 [pn,minp,maxp,tn,mint,maxt] = premnmx(RealInputs,RealOutputs);
7 P=pn.*0.4+0.5;
8 T=tn.*0.4+0.5;
9 net=newff(minmax(P), [size(P,1),NNeuronas,size(T,1)], {'logsig','logsig','logsig'}, 'traingdx','learnrnm
10
11
12
```

Figura 5.5 – Ventana de edición de archivos de secuencia y funciones.

### Ventajas

Este programa se emplea por las numerosas ventajas que presenta frente a otros que podrían desempeñar la misma función:

- Entorno integrado en Windows, con una interfaz clara e intuitiva.
- Posibilidad de intercambio de datos en formato ASCII, con el fin de poder analizar las respuestas con hojas de cálculo e introducir a su vez datos de las mismas como entradas.
- Elevada flexibilidad en los numerosos comandos disponibles.
- Permite guardar parcialmente los resultados sin esperar a la conclusión del programa (ventaja muy importante debido a que al emplear programas de ejecución larga resulta frecuente el bloqueo de Windows o de Matlab, con la consiguiente pérdida de datos).

- Programa veterano en el campo de las matemáticas, lo que le da una mayor posibilidad de tener buena depuración y estabilidad.
- Por contrato con la Universidad Complutense de Madrid, se dispone del programa en su versión completa.
- Se disponía de formación previa, con lo que el tiempo de aprendizaje se ha reducido considerablemente.

Por todas estas ventajas se ha elegido este programa para el manejo de redes neuronales y representación gráfica de algunos de los resultados.

### **Inconvenientes**

Matlab presenta algunos inconvenientes, que en este caso no han sido una barrera para su empleo:

- Precisa de un periodo de formación en el programa relativamente alto, debido a las expresiones particulares que emplea.
- Necesita ordenadores con prestaciones gráficas elevadas y buena velocidad, ya que las subrutinas se pueden llamar unas a otras en bucles que generan finalmente programas cuya ejecución resulta larga en tiempo.
- Es compleja la aplicación de una red a un simulador con posterioridad. Este inconveniente es común a prácticamente todos los programas que trabajan con redes neuronales, aunque existen simulaciones realizadas directamente en Simulink, dentro del entorno de Matlab.

Debido al elevado número de programas existentes, es obvio que no se puede entrar en detalle en todos ellos. En la bibliografía se encuentra algún caso de empleo de Matlab claramente apreciable (e.g. Campoy-Cervera et.al., 2001), pero no es fácil deducir el empleo de Matlab cuando se presentan casi exclusivamente resultados en la gran mayoría de los artículos consultados. Evaluando algunos programas y comprobando que ninguno de ellos supone una ventaja apreciable respecto a Matlab, unido a las ya citadas ventajas de utilizar Matlab como programa de trabajo, se decide, como ya se ha comentado, utilizar dicho programa para crear y manejar las redes neuronales necesarias para el desarrollo de la tesis.

### **5.2.3.Simulación de procesos industriales**

La alternativa elegida ha sido el simulador FlowMac, que funciona sobre el programa base Extend, por su especificidad en la industria del papel y su versatilidad de programación.

Como ya se ha indicado, FlowMac es un conjunto de bloques y librerías de equipos programados para ser ejecutados en Extend. Ha sido creado por la empresa PaperMac AB, y aprovecha la versatilidad de simulación de Extend para crear un entorno adecuado para simulaciones en la industria del papel. En el trabajo realizado se utiliza el programa para simular una planta de fibrocemento, con lo cual surgen algunas dificultades, debido a las diferencias existentes entre una planta de papel y otra de fibrocemento, en cuanto a los componentes del producto y su proporción en el mismo. Además existen equipos en el proceso muy diferentes cuyos bloques ha sido necesario desarrollar.

Al iniciar Extend, y abrir el archivo “modelling support” incluido en FlowMac, como un índice de los equipos existentes, se tiene una ventana como la mostrada en la figura 5.6.

El manejo de este programa es parecido al de otros programas de simulación. Primero se crea un diagrama de la planta a simular con los equipos disponibles, o creados por el usuario (en este sentido FlowMac, al disponer en sus equipos de código abierto, supone una gran ventaja al poderse personalizar cada bloque según las exigencias del proceso).

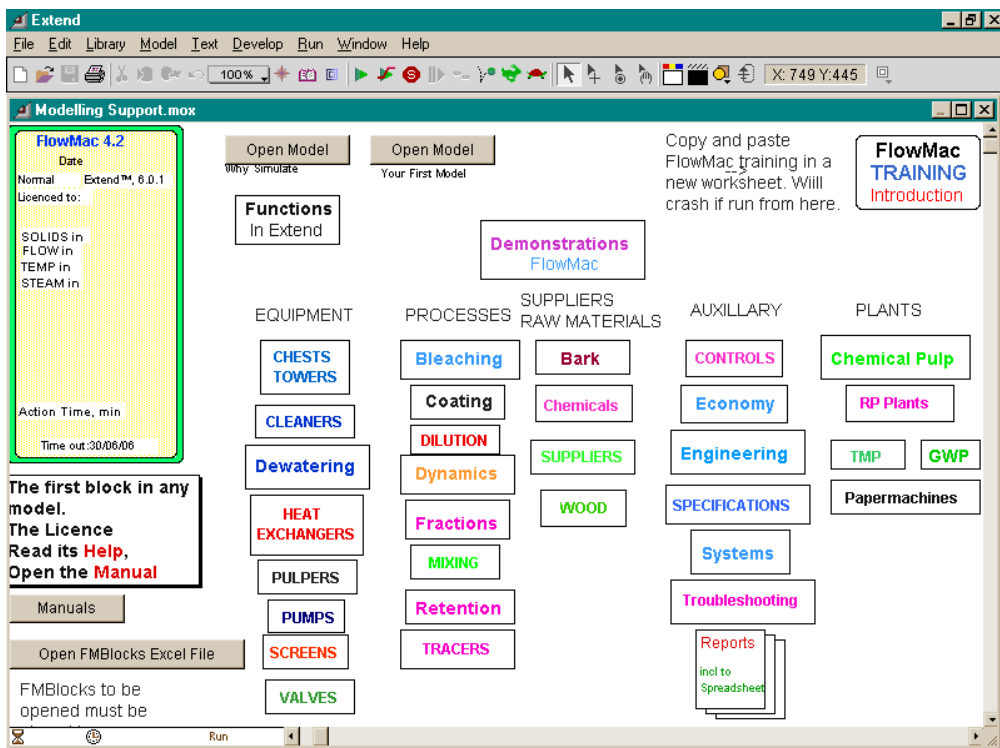


Figura 5.6 – Ventana principal de FlowMac, dentro del programa Extend v6.

En segundo lugar, se introducen los datos necesarios para comenzar la simulación. Una vez alcanzada la convergencia en este paso, se puede proceder a jugar con los datos de entrada, realizar análisis de sensibilidad, validar los resultados con datos tomados de la planta, etc.

### Ventajas

Frente al resto de programas analizados para realizar la simulación, FlowMac/Extend presenta las siguientes ventajas:

- Programa creado para la industria del papel, y adaptable a la del fibrocemento.
- Código abierto de los bloques existentes. Gran flexibilidad.

- Posibilidad de mejora de la programación de los bloques existentes.
- Entorno Windows. Facilidad para importar y exportar datos de Excel.
- Fácil paso a simulación dinámica.
- Posibilidad de programar simulación multicomponente por medio de trazadores (“tracers”) incluidos en la simulación.
- Trabaja con caudales volumétricos.

### **Inconvenientes**

Los inconvenientes más destacables del empleo de Extend/FlowMac son los siguientes:

- En principio no se trabaja con densidades. Para considerar diferentes densidades de sólidos se deben reprogramar algunos bloques.
- No se tienen en cuenta reacciones químicas. Se está trabajando para poder tenerlas en cuenta a través de bloques de ecuaciones.
- La forma de resolver la simulación es paso a paso, no pudiendo elegirse un sistema de ecuaciones como base para la simulación. Esto limita ciertos cálculos dinámicos a corto plazo.
- Dependencia de algún programador de FlowMac en cuanto a las futuras mejoras, no así en cuanto al empleo del programa.
- Si se emplea para fibrocemento, ha de tenerse especial cuidado con la programación de algunos bloques, y modificarla cuando proceda, en cuanto al tratamiento de fibras y aditivos de relleno.

#### **5.2.4. Análisis y procesamiento de datos**

En la elección de estos programas se busca no solo la disponibilidad y la facilidad de manejo, sino las posibilidades disponibles para la modificación de los datos originales según los sistemas empleados en las fábricas. Se han empleado los siguientes programas en esta tesis doctoral:

### ***Microsoft Excel***

Programa de creación de hojas de cálculo con posibilidades de programación automática en celdas. Fácil manejo y combinación con WinMOPS y Office, lo cual hace que su empleo suponga un considerable ahorro de tiempo.

### ***KCL-Wedge***

Se ha realizado una evaluación detallada del funcionamiento de este programa, con datos del proceso de fabricación de papel reciclado de la fábrica de Holmen Paper en Madrid (HPM), obtenidos mediante WinMOPS. Dicha evaluación realizada para KCL resulta confidencial, aunque se dispone de ella para posibles mejoras o comentarios.

### ***Statgraphics Plus***

Programa de análisis estadístico de datos. Sus resultados han de evaluarse con precaución, aunque como una primera herramienta resulta sencillo y práctico.

## **5.3. MÉTODOS DE TRABAJO**

Se han descrito hasta ahora los equipos con los cuales se lleva a cabo el trabajo de investigación. Se va a analizar ahora el método de trabajo con cada uno de ellos. Asimismo, se describirán las metodologías seguidas para elaborar la investigación principal en las industrias del fibrocemento y del papel.

### **5.3.1. Matlab**

Con este programa, el método de trabajo consiste en la creación de una estrategia clara en cuanto a los objetivos a conseguir, y con esa estrategia desarrollar los archivos función y de secuencia necesarios para llevarla a cabo. En la sección de resultados se detallará dicha metodología y, posteriormente, los programas desarrollados y su empleo.

### 5.3.2. Extend (FlowMac)

El método de trabajo con este programa de simulación es más sencillo, y se realiza de forma lineal. La dependencia del método de trabajo reside en el detalle de la simulación a realizar. Cada paso se explica con detalle a continuación.

1. Se crea el diagrama de la planta, eligiendo los equipos adecuados. En la presente investigación se ha comenzado por una simulación sencilla con bloques de mezcla y de separación. (Figura 5.7)
2. Se crean bloques complejos para facilitar la visión del diagrama.
3. Se añaden datos disponibles del proceso a cada equipo.
4. Se toman las suposiciones que sean necesarias.
5. Se valida la primera simulación con datos tomados de planta.
6. Se personalizan los diferentes equipos para eliminar suposiciones y hacer más realista la simulación.
7. Se toman nuevos datos que puedan necesitarse.
8. Se va validando cada cambio con los datos reales.
9. Se ofrece una simulación con el mínimo error posible.
10. Los nueve pasos anteriores se pueden realizar en simulación estática, dinámica, y para un componente o varios, en función del detalle deseado y de los datos disponibles.




Figura 5.7 – Ejemplo de creación de diagrama de planta con FlowMac.

Una de las características de los métodos de trabajo vistos es que, como en cualquier software informático, resultan fundamentales el manejo del programa con ejemplos de cualquier tipo, y la aplicación del método de prueba-error para llegar a una buena solución.

### 5.3.3. Metodología de la investigación

El proceso de construcción de los modelos se ha estructurado en una metodología compuesta por diferentes etapas. Algunas de ellas son secuenciales, mientras que otras tienen lugar en paralelo a lo largo de todo el proceso como, por ejemplo, la etapa de automatización del proceso mediante interfaces de usuario fáciles de emplear, que acelera el proceso de análisis y modelado. En el futuro esta tarea debería unirse al entrenamiento de operarios y a la implementación del modelo, toda vez que su utilidad haya sido probada y aceptada en fábrica, y éste resuelva las necesidades planteadas.

El desarrollo de una metodología clara y sistemática es uno de los puntos que quiere reforzar la presente tesis, ya que en la bibliografía estudiada se puede denotar la falta de un criterio claro a la hora de entrenar, validar y seleccionar los mejores modelos. El simple hecho de dedicar los recursos adecuados a la búsqueda de los mejores parámetros de cada modelo, y aplicarlo en cada problema, puede suponer mejoras muy significativas.

Las etapas que han sido propuestas en el proceso de modelado son las siguientes:

- ***Procesado previo de los datos:*** Los datos disponibles se filtran según las necesidades de cada modelo. En esta etapa se selecciona también el tipo de producto estudiado. Esta fase es crucial debido a que, una vez programados el resto de pasos, un porcentaje muy alto de errores se genera en la preselección de los datos, bien por ser sesgada, o bien por no filtrar adecuadamente determinadas situaciones como los fallos de los sensores, por ejemplo.
- ***Primera selección de variables:*** Ha de llevarse a cabo una primera selección de variables de proceso y medidas de laboratorio, teniendo

en cuenta la experiencia del personal de fábrica y de los investigadores. Esta selección puede ser modificada posteriormente si se encuentran correlaciones significativas entre los datos mediante el análisis estadístico de los mismos.

- **Análisis estadístico:** Esta etapa se lleva a cabo para tener una primera impresión del entorno de trabajo y ver las posibles correlaciones significativas entre las diferentes variables y medidas estudiadas.
- **Propuesta de técnicas de modelado:** Tras el análisis estadístico se deben proponer diferentes alternativas de técnicas de modelado, con el fin de construir herramientas de predicción de la calidad del producto, que permitan la optimización deseada, por ejemplo, si hablamos del papel, de la parte húmeda de la máquina. Como ya se ha indicado, entre las técnicas de modelado existentes, se han propuesto las regresiones múltiples y las redes neuronales artificiales (ANNs), debido a sus características, adecuadas para resolver las necesidades planteadas.
- **Definición del esquema de modelado:** Esta etapa asegurará unos modelos que cumplan los requisitos establecidos de robustez para la técnica de modelado seleccionada.
- **Modelado preliminar:** En esta etapa se seleccionan los parámetros óptimos de modelado mediante la creación de unos pocos modelos preliminares.
- **Estudio completo:** Tras la etapa anterior, se procede al modelado completo. Con esta etapa se evalúan los resultados obtenidos, la influencia de cada variable de entrada al modelo sobre cada variable de salida, y el cumplimiento de los objetivos marcados.
- **Segunda selección de variables:** Se lleva a cabo una selección más reducida con unas pocas variables de entrada y salida del modelo con los resultados del estudio completo. Los modelos que se crearán con esta nueva selección se llamarán modelos “de optimización”, y serán empleados únicamente si el objetivo último es la optimización del proceso o del producto, como es el caso en la presente tesis.

- **Modelado "de optimización":** Para construir los modelos reducidos se aplica la misma secuencia de modelado preliminar/completo. En este caso, el número reducido de variables de entrada permite un análisis más profundo de los resultados, obteniéndose recomendaciones que permitan cumplir los objetivos.
- **Actualización/mejora de los modelos:** Finalmente, se puede aplicar un procedimiento de actualización/mejora automática de los modelos, con el fin de mantener su robustez en el tiempo según se disponga de nuevos datos, e incluso crear nuevos modelos cuando las condiciones de operación cambien significativamente.

Dentro de la definición del esquema de modelado, se ha desarrollado un sistema que permita tener un buen porcentaje de éxito en la búsqueda del mejor modelo, sin necesidad de dedicar una cantidad inviable de recursos, creando múltiples modelos que combinen estos parámetros sin seguir un esquema concreto.

Hay que destacar que técnicas como los árboles de decisión o los algoritmos genéticos emplean una cantidad tal de recursos de cálculo que, si se dispone de un sistema potente de cálculo, pueden resultar adecuadas, pero si no, el tiempo necesario para llegar a una buena solución las convierte en inviables.

### ***Optimización de la arquitectura y el algoritmo de entrenamiento***

En el caso del papel, un parámetro que no se ha decidido optimizar es el número de capas ocultas presentes en la red neuronal. La experiencia previa en el caso del fibrocemento nos muestra que, para este caso específico, una capa oculta es suficiente para el modelo. Con dos capas podría llegarse a resultados similares, pero la cantidad de tiempo necesaria para el desarrollo de los modelos es mucho mayor.

De la misma forma se ha procedido a elegir las funciones de transferencia de los diferentes nodos. La combinación de función logística en la capa de entrada y capa oculta con la función lineal en la capa de salida, proporciona una capacidad de modelado excelente, a la vez que ahorra gran cantidad de tiempo de computación en la reducción de los errores de entrenamiento.

Por tanto, esta etapa incluye el desarrollo de varios modelos, modificando el número de neuronas de la capa oculta (neuronas ocultas) y el algoritmo de entrenamiento. Se han propuesto dos algoritmos de entrenamiento: el algoritmo de Levenberg-Marquardt (LMA) y el de gradiente descendente (GDA) con momento y factor de aprendizaje variable. En el caso del algoritmo GDA surge otro parámetro a optimizar: el valor del momento.

Se han desarrollado cinco redes neuronales para cada combinación de parámetros. Mediante archivos de programación desarrollados en la presente tesis, es posible una selección automática de aquellos modelos con menor error de validación, grabando sus parámetros y analizando sus resultados. El modo de trabajo en la fase de optimización de arquitectura se muestra en la figura 5.8.

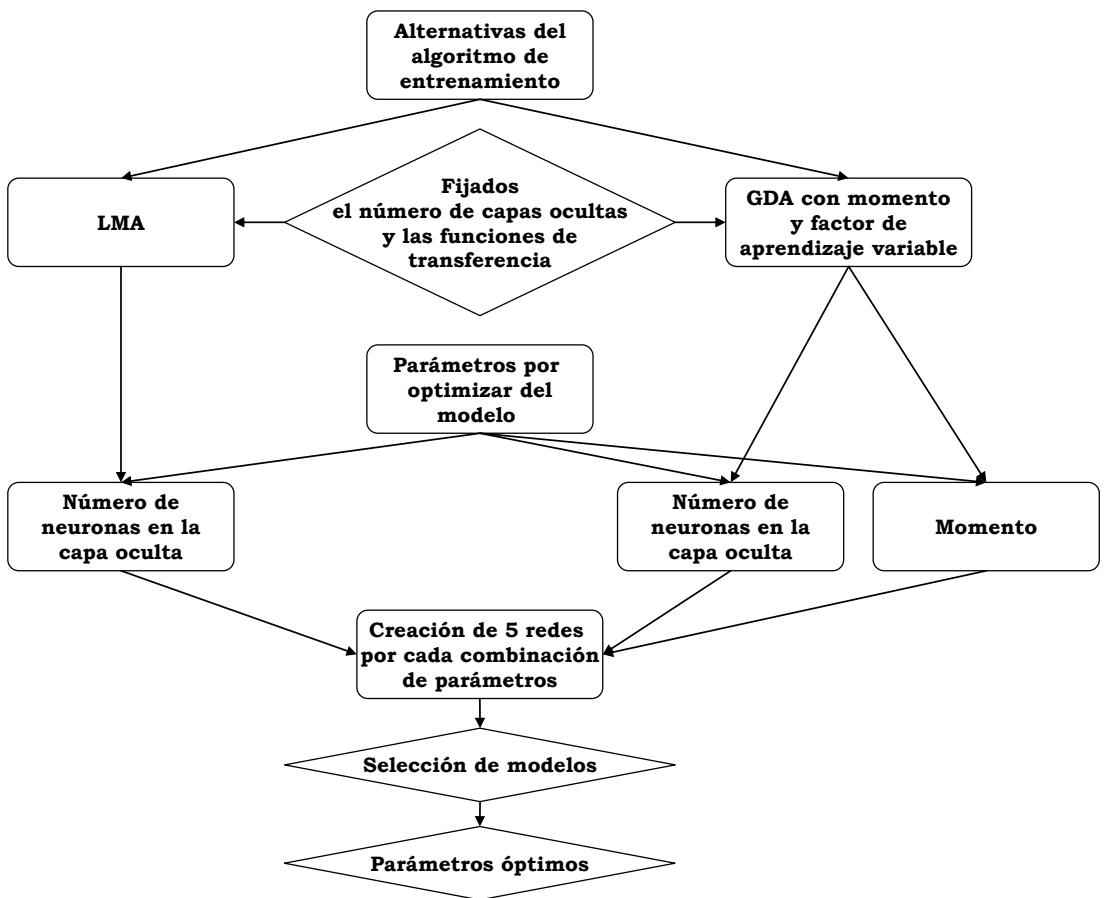


Figura 5.8 – Esquema de optimización de la arquitectura de red.

### *Selección y agrupamiento de las mejores redes*

Una vez optimizados la arquitectura y el algoritmo de entrenamiento, en el caso de los estudios completos, se presenta otro paso que variará dependiendo del análisis.

En un estudio completo se crean varias redes para comparar, por ejemplo, en el caso de la presente tesis, distribuciones de datos diferentes en el tiempo respecto al intervalo de tiempo de entrenamiento. Cada distribución de datos estudiada implica la creación de redes neuronales valores óptimos de los parámetros obtenidos con anterioridad. Es frecuente que más que un único valor óptimo, se presente un intervalo ajustado de valores.

De todos los modelos desarrollados, los mejores se seleccionan para analizar sus errores de validación y simulación. La figura 5.9 muestra un esquema del proceso de selección.

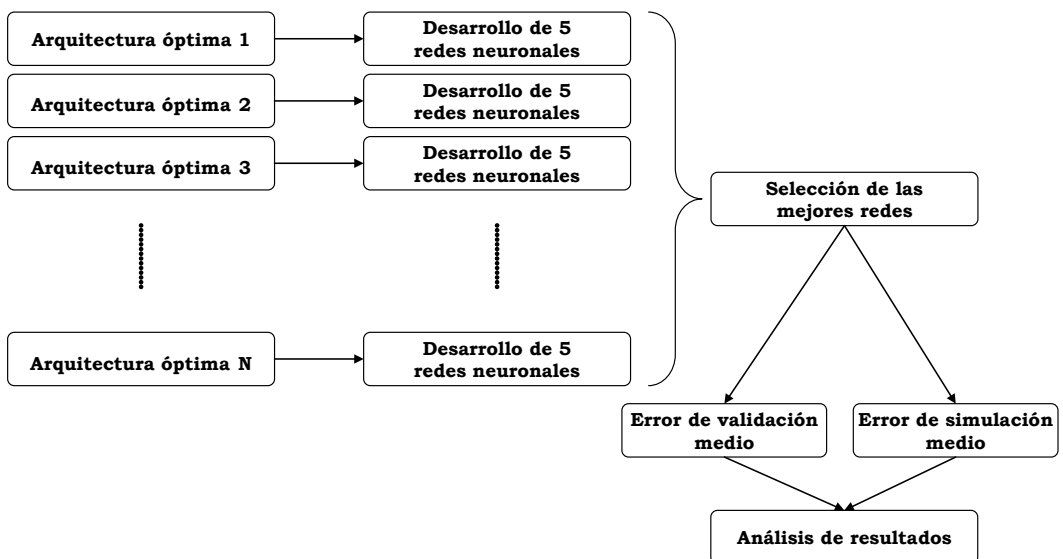


Figura 5.9 – Selección de las mejores redes. El proceso se basa en la búsqueda del mínimo error de validación.

### ***Entrenamiento, validación y simulación***

El error de validación se emplea durante el entrenamiento de los modelos para seleccionar el número óptimo de iteraciones. Los datos de validación no se emplean para entrenar la red, sino para comprobar su funcionamiento. Los errores de simulación se calculan de forma idéntica, pero su propósito es comprobar la robustez del modelo ya creado, cuando se le enfrenta a datos de periodos de tiempo distintos.

En cada paso de la definición del esquema de modelado, los términos “entrenamiento”, “validación” y “simulación” se presentan constantemente. Ya en los comentarios previos de la presente tesis se ha hecho hincapié en sus diferencias. La validación y la simulación implican únicamente el cálculo de las salidas de la red neuronal, pero con objetivos diferentes según los datos introducidos sean los de validación o simulación.

Por otra parte, se pueden presentar distintos criterios de parada al entrenar las redes neuronales. Lógicamente el proceso de entrenamiento depende de estos criterios. En la presente tesis se ha seleccionado como criterio el mínimo error de validación, si bien existen otros métodos más útiles en otras aplicaciones, como la elección del modelo con menor suma de pesos internos, incluso con combinaciones de esa suma con el error de validación, o criterios dependientes del error de entrenamiento y no del de validación, como la búsqueda de error mínimo de entrenamiento o de una diferencia concreta entre el error de una iteración y el de la siguiente.

Según el criterio de parada elegido, ha de buscarse un error mínimo de validación. Se valida cada red neuronal cada cierto número de iteraciones (esta cantidad puede variarse libremente con los programas desarrollados, mediante una interfaz). El número óptimo de iteraciones es aquel en el que se alcanza un error mínimo de validación, calculado como la diferencia entre las respuestas de la red y los datos de validación. Se puede observar en la figura 5.10 una vista esquemática de este proceso.

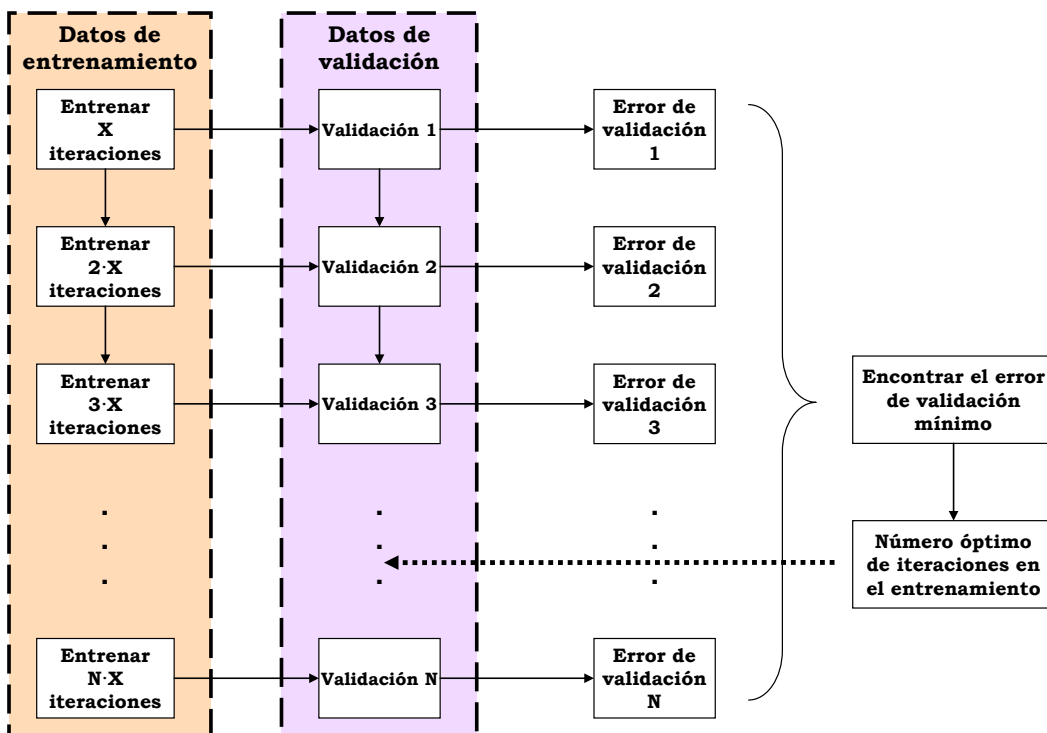


Figura 5.10 – Esquema de la selección de número óptimo de iteraciones.

Al entrenar cada modelo, se realiza automáticamente una representación gráfica de los errores de entrenamiento y validación frente al número de iteraciones, y se guardan automáticamente sus valores, para automatizar la selección de las mejores redes y el posterior análisis de resultados.

### 5.3.3.1. Fibrocemento

En este caso, la ausencia de medidas de otros sensores hizo necesario el emplear medidas del sensor FBRM para la creación de los modelos. Debido a la multitud de estadísticos y medidas que se pueden obtener, una primera fase ha consistido en la búsqueda de las mejores medidas para su inclusión en los modelos finales (RED-A en la figura 5.11). El posterior estudio sigue la metodología común desarrollada en la presente tesis.




Figura 5.11 – Esquema de la metodología seguida en el caso del fibrocemento.

En este caso, al tener productos de características muy diferentes, simplemente dependiendo del perfil del producto, se ha comenzado desarrollando redes para un solo perfil. En la fase final del estudio, se ha generado un modelo válido para varios perfiles, con gran capacidad de generalización, que resulta de gran utilidad para, por ejemplo, el control de calidad instantáneo en planta.

### 5.3.3.2. Papel

La metodología propuesta para el caso del fibrocemento se ha validado y aplicado con éxito para optimizar la calidad del papel en HPM con datos tomados de la parte húmeda de la máquina de papel durante dos años. En este caso, la preselección de las variables empleadas en los modelos ha adquirido una mayor importancia, debido a la gran disponibilidad de datos.

Tras esta preselección, se ha adaptado la metodología empleada en la fábrica de fibrocemento, de tal forma que se han generado redes neuronales para todas las salidas definidas en el apartado de resultados. De este modo se ha podido optimizar el tamaño de las redes, los algoritmos y parámetros empleados, e incluso repetir baterías de experimentos para determinar el efecto sobre la calidad de las predicciones de la inclusión de medidas de equipos como el FBRM o el Kajaani, e incluso determinar la cantidad y temporalidad necesaria de datos de validación para obtener resultados más robustos, basándose en la metodología desarrollada y explicada en el apartado 5.3.3.

También se han desarrollado regresiones multivariable, con el objetivo de validar la necesidad de empleo de las redes neuronales. En los casos estudiados, las redes predicen con una fiabilidad significativamente mayor, como se verá más adelante.

## 6. RESULTADOS Y DISCUSIÓN

A través de la investigación realizada se obtienen unos resultados primarios, que, tras ser analizados mediante distintos métodos, proporcionan resultados secundarios, a través de los cuales, generalmente, se pueden obtener las conclusiones oportunas. Dicha estructura permite la diferenciación del trabajo entre experimentación y análisis de resultados.

Las actividades realizadas han sido la creación de varias redes neuronales, con las que se buscan relaciones entre medidas del sensor FBRM y propiedades finales del fibrocemento, y la simulación de una planta de producción de este material de construcción, utilizando para ello el paquete de bloques de simulación FlowMac, empleado junto con el programa base Extend.

El modelado de procesos comprende diferentes técnicas que pueden ser empleadas para la construcción de sensores virtuales, simulaciones y herramientas de diagnóstico, con diferentes objetivos como la monitorización del sistema, la predicción de su comportamiento en diferentes condiciones y la optimización de la calidad del producto o de la manejabilidad de la producción.

Los resultados de cada modelado dependen de diferentes variables, como el análisis de los datos, la eliminación de aquellos erróneos o no significativos, la elección de la técnica de modelado adecuada o el cómo se usa cada técnica. Por tanto, la selección de una metodología adecuada resulta crucial en cada paso de la investigación.

Algunas secciones de la fabricación de papel y fibrocemento resultan especialmente complejas de modelar matemáticamente. Por ejemplo, la parte húmeda de la máquina de papel, cuya físico-química no ha sido todavía bien descrita y, por tanto, no se han desarrollado modelos determinísticos. Por ello se hace necesario el empleo de técnicas avanzadas para su monitorización y la predicción de propiedades del producto. Algo similar pasa con el proceso de floculación, retención y drenaje.

Sin embargo, el empleo de estas técnicas no es una decisión que pueda tomarse a priori. Antes de eso, ha de realizarse un estudio preliminar para comparar distintas alternativas de modelado y descartar las más sencillas únicamente cuando los resultados mejoren significativamente al emplear otras más complejas. La razón

de utilizar modelos lo más sencillos posibles radica en la posterior facilidad de implementación y/u optimización del proceso.

Si se descartan los métodos más simples (por ejemplo, en el caso de esta tesis, las regresiones múltiples o análisis estadísticos convencionales), el siguiente paso para una implementación exitosa es demostrar en el entorno de fábrica que esos modelos ‘de caja negra’, ‘complejos’ o ‘avanzados’ no son herramientas ‘místicas’ entendibles solo para unos pocos. Al contrario, la estrategia debe centrarse en probar con ejemplos sencillos que esos modelos, utilizados por ejemplo para construir sensores virtuales, proporcionan los resultados exactamente igual que el más simple de los modelos. La única diferencia estriba, por tanto, en el conocimiento necesario para crear los modelos o para implementarlos, no para usarlos en el día a día de la fábrica. Todas las etapas anteriores y posteriores al modelado no tienen por qué ser distintas.

Cuando se construye un modelo para emplearlo como sensor virtual, se deben definir los objetivos claramente. Según el modelo que se emplee para predecir, monitorizar u optimizar el sistema estudiado, los requerimientos en el número de entradas y salidas del modelo serán diferentes, con lo cual la exactitud de las predicciones no será más que otro factor a tener en consideración, aparte del tiempo y los recursos necesarios para crear el modelo.

Para una optimización, lo más importante es poder traducir los resultados de las predicciones de los modelos en acciones concretas que tengan su correspondiente efecto. Por tanto, un número reducido de entradas permitiría esta aplicación, aún pese a perderse capacidad de predicción. La solución aportada por un modelo es más sencilla de aplicar cuantas menos variables incluya. Un modelo de una sola variable de entrada haría desaparecer estas dificultades, pero no sería lo suficientemente exacto en la mayoría de las ocasiones. Ha de buscarse por tanto una solución de compromiso.

Por el contrario, cuando lo que se busca es una predicción lo más exacta y precisa posible, la selección de pocas variables no es la mejor opción. De cualquier modo ha de evitarse el trabajar con variables altamente interdependientes.

De todo ello se deduce que han de definirse como objetivos el número de variables y un grado determinado de exactitud y robustez. Existen infinitas

posibilidades entre un modelo robusto a largo plazo, y uno muy exacto para un periodo concreto, pero poco fiable para el resto de periodos.

La etapa de modelado se verá influenciada tanto por las técnicas seleccionadas como por el grado de robustez elegido. Como parte de la investigación llevada a cabo, por ejemplo, cuando una red neuronal ha sido entrenada y validada, el criterio de parada ha sido la robustez, medida mediante una comprobación del modelo con datos de validación tomados de diferentes periodos de tiempo que aquellos empleados para su entrenamiento.

Finalmente, los resultados se pueden mostrar de diferentes formas, pero han de ser tratados para ser fácilmente entendibles, siguiendo la misma estructura que los objetivos. El concepto debe consistir en que las matemáticas implícitas en los modelos pueden ser relativamente complejas, pero su aplicación en fábrica resulta tan fácil como una regresión lineal simple.

En este apartado, se presentan en primer lugar los resultados primarios, detallando posteriormente los secundarios, como apartados de éstos, y terminando con las previsiones y recomendaciones para cada proceso estudiado.

A modo de resumen, en el caso del fibrocemento, se tienen los siguientes resultados primarios:

- Obtención de regresiones polinómicas.
- Obtención de esas mismas regresiones fijando la densidad en tierno constante.
- Desarrollo de programas de creación y optimización de redes neuronales, así como para realizar diferentes representaciones gráficas.
- Creación de redes neuronales para fibrocemento.
  - Obtención de una red neuronal de 7 entradas y 7 salidas (RED-A).
  - Obtención de redes de 3 entradas y 1 salida para predicción de propiedades específicas de resistencia del fibrocemento (Redes B, C y D).
  - Obtención de una red neuronal de 3 entradas y 6 salidas con datos de producción para un perfil (RED-E).

- Obtención de una red neuronal de 3 entradas y 6 salidas con datos de producción para varios perfiles (RED-F).
- Definición de una estrategia para la creación y optimización de redes neuronales aplicadas a procesos industriales.
- Simulación de una planta industrial de obtención de fibrocemento.
- Obtención de datos de comprobación.

En el caso del papel, se tienen los siguientes resultados primarios:

- Obtención de regresiones polinómicas (trabajos previos del grupo de investigación).
- Desarrollo de programas de creación y optimización de redes neuronales, así como para realizar diferentes representaciones gráficas.
- Creación de redes neuronales para la industria pastero-papelera.
  - Obtención de redes neuronales preliminares.
  - Obtención de redes definitivas.
  - Definición de una estrategia para la creación y optimización de técnicas avanzadas de análisis de datos, aplicadas a procesos industriales.
- Simulación de una planta industrial de obtención de papel, basada en datos obtenidos en trabajos previos.
- Obtención de datos de comprobación.

Los resultados llevan un orden lógico de actuación. Primero se buscan correlaciones por los métodos clásicos, y al comprobar el bajo índice de correlación existente, o la poca reproducibilidad del método, se opta por el empleo de sistemas de predicción de comportamientos complejos, como son las redes neuronales. En la obtención de éstas se desarrollan unos programas específicos, así como una estrategia de obtención de redes neuronales. Por último, todo ello será aplicable a la simulación de plantas industriales.

Tanto las redes neuronales como la simulación se basan en datos tomados en fábrica, y necesitan comprobaciones periódicas realizadas con tomas de nuevos datos.

## 6.1. PRODUCCIÓN DE FIBROCEMENTO

### 6.1.1. Obtención de regresiones polinómicas

El primer paso en el estudio de la influencia de las medidas del sensor FBRM (tomadas en uno de los tanques con rodillos de formación de una capa de fibrocemento de una línea de producción de la empresa Fibrocementos NT, en su planta de Valladolid) sobre las propiedades finales del fibrocemento, es la obtención de regresiones polinómicas que relacionen dichas medidas con diferentes propiedades del fibrocemento, como son en índice de clase ( $F_s$ ), el momento flector ( $M$ ), la densidad y el espesor, tomados a diferentes tiempos tras la fabricación, debido a que el fibrocemento sufre un proceso de fraguado, de larga duración, con lo que sus propiedades varían ligeramente con el tiempo.

Dichas correlaciones proporcionan resultados muy discretos en cuanto a índices de correlación, y se presentan en el Anexo I en su totalidad. Se pueden observar algunos ejemplos de ellas en las figuras 6.1 a 6.3. El empleo de polinomios de grado superior al lineal se justifica por la búsqueda de coeficientes de correlación superiores a 0.5, considerados de posible aplicación industrial, así como por el aumento significativo de este coeficiente en algunos casos al aumentar el grado del polinomio.




Figura 6.1 – Ejemplo de representación gráfica obtenida. Densidad a los 7 días frente al número de cuentas por segundo de partículas entre 10 y 32 μm (Anexo I).

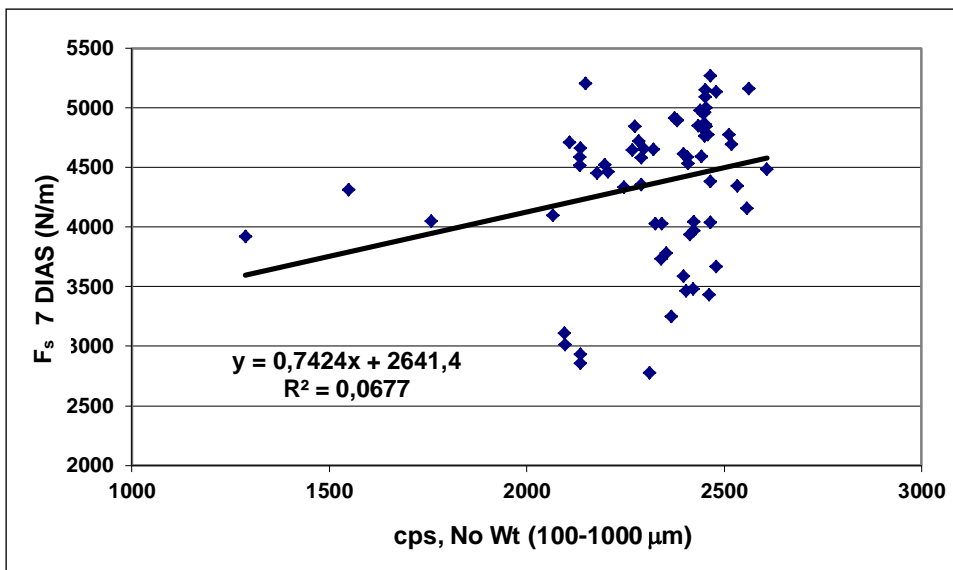


Figura 6.2 – Ejemplo de representación gráfica obtenida. Índice de Clase a los 7 días frente al número de cuentas por segundo de partículas entre 100 y 1000  $\mu\text{m}$  (Anexo I).




Figura 6.3 – Ejemplo de representación gráfica obtenida. Momento Flector a los 7 días frente al número de cuentas por segundo de partículas entre 100 y 1000  $\mu\text{m}$  (Anexo I).

En la tabla 6.1 se resumen todos los coeficientes de correlación lineal obtenidos, para tener una idea clara de la calidad de las diferentes correlaciones encontradas que, en la gran mayoría de los casos, resulta ser muy deficiente, con valores rara vez cercanos a 0.5 que, por la experiencia del personal de planta podría ser un valor mínimo a considerar, y muy frecuentemente cercanos a 0.

Tabla 6.1 – Coeficientes de correlación ( $R^2$ ) obtenidos para las regresiones lineales.  
(Gráficas en el anexo I).

	$F_s$ 48 HORAS (N/m)	ESPESES. 48 h. (mm)	$F_s$ 7 DÍAS (N/m)	ESPESES. 7 d. (mm)	$M$ 7 DÍAS (N·m/m)	DENS. 7 d. (g/cm <sup>3</sup> )	$F_s$ 40 DÍAS (N/m)	ESPESES. 40 d. (mm)	DENS. 40 d. (g/cm <sup>3</sup> )
$\rho_{\text{tierno}}$ (g/cm <sup>3</sup> )	0.30	0.040	0.52	0.024	0.038	0.69	0.47	0.080	0.67
10-32 $\mu\text{m}$ (cps)	0.040	0.014	0.068	0.017	0.28	0.0001	0.055	0.022	0.013
100-1000 $\mu\text{m}$ (cps)	0.016	0.0012	0.068	0.012	0.13	0.027	0.053	0.0011	0.0047
50-86 $\mu\text{m}$ (cps)	0.059	0.011	0.053	0.046	0.31	0.029	0.036	0.0082	0.029
% 10-86 $\mu\text{m}$	0.11	0.015	0.15	0.036	0.34	0.0070	0.12	0.014	0.0015
Ctas.Totales (cps)	0.045	0.014	0.059	0.023	0.30	0.0047	0.044	0.018	0.025
Ctas.Totales. Med (cps)	0.0034	0.00004	0.018	0.0016	0.18	0.0045	0.0004	0.0019	0.014

En vista de los bajos coeficientes de correlación obtenidos, se propone el realizar estas representaciones para valores de densidad en tierno constante.

### 6.1.2. Obtención de regresiones fijando la densidad en tierno constante

Las regresiones obtenidas fijando la densidad en tierno constante se recogen en el anexo II, y siguen las mismas combinaciones que en el anexo I. En estos casos se obtienen mejores índices de correlación, con valores mucho mayores, superando en algunos casos el 0.9 y frecuentemente por encima de 0.7,

pero la pequeña cantidad de datos para cada representación, y sus intervalos de representación, hacen que la repetibilidad de estas tendencias sea muy pequeña.

Algunos valores de densidad en tierno no han sido representados, bien porque se dispone de datos insuficientes para ello o bien por la imposibilidad de poder compararlos con valores más cercanos (caso de valores de 1.80 á 1.90). Se han representado aquellos que permiten intentar obtener conclusiones de la comparación entre ellos, sin una extrapolación que podría resultar poco eficiente por los pocos datos disponibles en otros intervalos de valores.

En general se observan numerosos casos de índices de correlación por encima de 0.5. Tal vez debido al error experimental, o a un comportamiento caótico de propiedades, quedan también numerosos casos de ajustes con muy baja correlación, de los cuales en principio no pueden obtenerse muchas conclusiones salvo, en algún caso, la apreciación de un comportamiento acorde a otras correlaciones.

Cualquier resultado obtenido ha de ser evaluado con precaución, debido a lo complejo de este comportamiento. De hecho, simplemente la escala elegida en la representación puede hacer que una nube de puntos se vea como una línea, estirando un eje y acortando el otro, con lo que se debe tener cuidado con posibles apreciaciones indebidas que lleven a error.

En cuanto a tendencias de comportamiento de algún parámetro con la variación de la densidad, no se aprecia ninguna significativa. Lo que sí se observa es un cierto parecido en las representaciones para una misma variable y un mismo valor de densidad. Esto se debe a que el número de cuentas de diferentes tamaños suelen estar relacionados entre ellos, de tal forma que su relación con las distintas variables guarda un cierto parecido en algunos casos. En las figuras 6.4 y 6.5 se muestran ejemplos de estas gráficas.




Figura 6.4 – Ejemplo de las representaciones obtenidas para valores de densidad en tierno constante, y en este caso igual a 1.92 g/cm<sup>3</sup> (Anexo II).




Figura 6.5 – Ejemplo de las representaciones obtenidas para valores de densidad en tierno constante, y en este caso igual a 1.92 g/cm<sup>3</sup> (Anexo II).

### 6.1.3. Obtención de redes neuronales para fibrocemento

Debido a esa baja reproducibilidad en cada representación, se opta por el empleo de redes neuronales. Como ya se ha indicado, estos sistemas sirven para la predicción, control y análisis de sistemas con comportamientos complejos.

Los detalles de cada aspecto de la creación y análisis de datos en estas redes se muestran en detalle en el anexo III, donde se pueden observar los efectos de la variación de una entrada a la red, manteniendo el resto constantes, para determinar las entradas más influyentes, combinando este estudio con diversos diseños de experimentos, incluidos en el anexo IV. El anexo V recoge las pruebas de diferentes combinaciones de parámetros para crear las redes neuronales, mostrando en cada caso los errores de entrenamiento y predicción. Por último, el anexo VI muestra los resultados de la generación de superficies de respuesta, que se observan en los resultados de la tesis doctoral. En el CD adjunto a la tesis se incluyen los vídeos generados al concatenar los gráficos por orden de densidades en tierno.

#### 6.1.3.1. Resultados experimentales e interpretación

##### 6.1.3.1.1. Red neuronal "A"

El primer paso dentro del esquema de la investigación es construir una red neuronal con 7 estadísticos tomados de las medidas del sensor FBRM como entradas, y 7 salidas, que son diferentes propiedades del fibrocemento, como puede verse en la tabla 6.2. Esta red presenta como objetivo la elección del estadístico más representativo sobre la resistencia del fibrocemento, mediante dos técnicas diferentes de análisis de la influencia de cada entrada a la red.

Tabla 6.2 – Entradas y salidas de la RED-A.

Entradas (Número de cuentas por segundo de partículas...)	Salidas
...entre 1 y 5 $\mu\text{m}$ (cps)	$F_s$ a las 48 horas (N/m)
...entre 5 y 10 $\mu\text{m}$ (cps)	$E$ a las 48 horas (mm)
...entre 10 y 32 $\mu\text{m}$ (cps)	$F_s$ a los 7 días (N/m)

<b>Entradas</b> (Número de cuentas por segundo de partículas...)	<b>Salidas</b>
...entre 32 y 50 $\mu\text{m}$ (cps)	<i>E</i> a los 7 d (mm)
...entre 50 y 86 $\mu\text{m}$ (cps)	<i>M</i> a los 7 d (N-m/m)
...entre 86 y 100 $\mu\text{m}$ (cps)	<i>d</i> a los 7 días (kg/L)
...entre 100 y 1000 $\mu\text{m}$ (cps)	<i>d</i> en tierno (kg/L)

Los parámetros de esta red neuronal se presentan en la tabla 6.3. El método de optimización en la red neuronal ha sido ligeramente distinto que en las siguientes, ya que se ha recurrido al método de prueba-error, frente a la posterior optimización por medio de combinación de valores de distintos parámetros.

Tanto en el método de prueba-error, como en la combinación de valores de parámetros, siempre se busca una función objetivo, que es la minimización del error de validación de la red neuronal, es decir, el error que ésta comete al simular las salidas con datos que no se han empleado para entrenarla.

El error global de predicción con esta red ha sido del 9.3%. Dicho error es el valor medio, considerando el error cometido para cada variable como un porcentaje del intervalo entre los valores mínimo y máximo de los datos reales empleados para el entrenamiento. Los resultados se muestran en la tabla 6.4.

Tabla 6.3 – Parámetros de la RED-A. Valores y criterios de elección.

<b>Parámetro</b>	<b>Valor</b>	<b>Criterio de elección</b>
Algoritmo de entrenamiento	Retropropagación de tipo descenso de gradiente con factor de aprendizaje variable.	Fijado
Tipo de función de transferencia	Ecuación logística	Prueba - error (error de validación)
Factor de aprendizaje	Variable (Debido al algoritmo de entrenamiento) Valor inicial = 0.05	Ligado al algoritmo de entrenamiento
Momento	0.95	Prueba - error (error de validación)
Número de capas ocultas	2	Prueba - error (error de validación)

Parámetro	Valor	Criterio de elección
Número de neuronas en las capas ocultas	20 en cada capa	Prueba - error (error de validación)
Número de iteraciones	30000	Optimización del error de validación
Número de datos totales	139	Datos disponibles
Datos para validación	18	Elegidos al azar

Tabla 6.4 - Error medio porcentual para cada variable de salida (RED-A).

	Tierno	48 horas		7 días			
	$d$	$F_s$	$e$	$F_s$	$e$	$M$	$d$
Error medio porcentual	7.7	6.4	14.3	7.9	8.0	12.0	8.8

Los mejores resultados se obtienen con las predicciones del  $F_s$  a 48 horas y 7 días (ver figura 6.6), y la densidad en tierno. Los peores resultados corresponden al espesor a las 48 horas. Las predicciones de los espesores no son en general robustas, y esto es debido a que no son variables de proceso, sino parámetros fijados por el operario, cambiando el número de vueltas que da la placa primaria en el cilindro formador. Dichos espesores se han incluido para observar la capacidad de las redes neuronales para distinguir entre variables predecibles e impredecibles. La importancia de esta distinción será mayor en las redes E y F, que tienen como objetivo optimizar las predicciones.

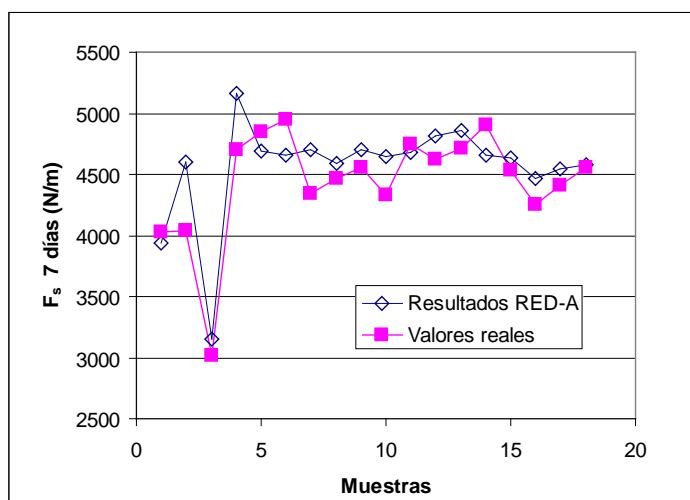


Figura 6.6 - Valores reales y predicciones de la RED-A para las muestras de validación.

La importancia de cada estadístico del sensor FBRM depende de cómo afecte la floculación al proceso de fabricación. Tras la adición del floculante, mientras el proceso se equilibra, la distribución de tamaños de partícula cambia. Pequeños cambios en la adición del floculante, en las condiciones de operación e incluso en las propiedades de las materias primas pueden hacer variar esta distribución. Mediante los estadísticos apropiados, estas pequeñas diferencias pueden observarse, siendo más significativos los cambios cuando se trata de estadísticos de valores suma, medias o medianas de tamaños de partícula. Por tanto, una correcta elección de los estadísticos será muy importante para las siguientes etapas de la investigación.

Chitra ha descrito un método para analizar los pesos de una red neuronal de alimentación hacia delante, para calcular la influencia de cada entrada a la red sobre las salidas (Chitra, 1993). Siguiendo este método, la diferencia entre la influencia de cada estadístico resulta muy pequeña (ver tabla 6.5). Para garantizar que el estadístico elegido es el mejor de los estudiados, se ha realizado un estudio más detallado, considerando la red neuronal como un laboratorio, y realizando un diseño factorial de experimentos  $2^7$ , variando las entradas a la red neuronal y evaluando el efecto sobre las salidas analizando los diagramas de Pareto.

Tabla 6.5 – Efecto de cada entrada según análisis de pesos, ANN-A.

Medidas del FBRM (cps) para tamaños de partícula entre...	...1-5 $\mu\text{m}$	...5-10 $\mu\text{m}$	...10-32 $\mu\text{m}$	...32-50 $\mu\text{m}$	...50-86 $\mu\text{m}$	...86-100 $\mu\text{m}$	...100-1000 $\mu\text{m}$
Efecto %	0.12	0.17	0.15	0.15	0.13	0.14	0.15

En la tabla 6.6 se muestran los valores empleados en el diseño de experimentos. Los efectos más importantes son los de cada entrada sobre el  $F_s$  a las 48 horas y a los 7 días, y el  $M$  a los 7 días, porque estas propiedades representan propiedades mecánicas, cuya importancia hace que sean aquellas a optimizar con las siguientes redes neuronales. Por tanto, no se considerarán otros efectos para la elección del estadístico más significativo.

Tabla 6.6 – Valores empleados en el diseño de experimentos 27.

Medidas del FBRM (cps) para tamaños de partícula entre...	...1-5 $\mu\text{m}$	...5-10 $\mu\text{m}$	...10-32 $\mu\text{m}$	...32-50 $\mu\text{m}$	...50-86 $\mu\text{m}$	...86-100 $\mu\text{m}$	...100-1000 $\mu\text{m}$
Valor +1	637	1245	6072	4154	3515	839	3036
Valor -1	63	159	875	748	1051	324	1396

El principal resultado obtenido mediante el diseño de experimentos es que los dos estadísticos claramente más significativos para las propiedades finales del fibrocemento son las *cps* medidas para partículas entre 10 y 32  $\mu\text{m}$ , y para partículas entre 5 y 10  $\mu\text{m}$ . Los resultados del análisis se muestran en la tabla 6.7. Debido a que el efecto de las *cps* medidas para partículas entre 10 y 32  $\mu\text{m}$  es ligeramente mayor, éste ha sido elegido como el estadístico más significativo, que se empleará como entrada para las siguientes redes neuronales.

Tabla 6.7 – Suma de efectos significativos estandarizados de cada estadístico del FBRM sobre el  $F_s$  a las 48 horas,  $F_s$  a los 7 días y  $M$  a los 7 días, en el diseño 27.

Medidas del FBRM (cps) para tamaños de partícula entre...	...1-5 $\mu\text{m}$	...5-10 $\mu\text{m}$	...10-32 $\mu\text{m}$	...32-50 $\mu\text{m}$	...50-86 $\mu\text{m}$	...86-100 $\mu\text{m}$	...100-1000 $\mu\text{m}$
Valor	2.11	6.20	<b>6.26</b>	2.64	2.49	1.07	0

#### 6.1.3.1.2. Red neuronal "B"

Esta nueva red neuronal se ha creado, teniendo como entradas el estadístico más significativo del sensor FBRM, obtenido con la RED-A, el número total de cuentas por segundo (de partículas entre 1 y 1000  $\mu\text{m}$ ), y la densidad en tierno. Esta densidad se ha tomado para mejorar en robustez las predicciones, ya que en planta se emplea como un primer control de la calidad de la placa, siendo preferidos a priori valores elevados. El número total de cuentas resulta un valor claramente significativo, a la vez que fácilmente manejable, con lo cual se facilita la posterior optimización del proceso.

Cabe destacar que, al tener como objetivo no solo el alcanzar buenas predicciones, si no también, a partir de dichas predicciones, optimizar el proceso, las entradas a la red han de ser fáciles de modificar cambiando las condiciones de operación o la dosis de floculante. Las tres entradas propuestas para las redes creadas cumplen con los requisitos expuestos.

Las redes neuronales B, C y D se han obtenido con datos tomados en diferentes campañas de producción y en diferentes épocas del año, con el fin de tener datos representativos y robustos, evitando la estacionalidad. Los parámetros empleados en estas tres redes, así como los criterios de selección, se muestran en la tabla 6.8.

Tabla 6.8 – Parámetros de las redes B, C y D. Valores y criterios de elección.

Parámetro	Valor	Criterio de selección
<b>Todas las redes neuronales</b>		
Algoritmo de entrenamiento	Retropropagación (algoritmo de gradiente decreciente con factor de aprendizaje variable)	Fijado
Función de transferencia	Sigmoidal logística (Todas las capas)	Prueba - error (Errores de predicción)
Factor de Aprendizaje	Variable (debido al algoritmo de entrenamiento) Valor inicial = 0.05	Unido al algoritmo de entrenamiento
Capas ocultas	1	Fijado (Experiencia previa)
Datos totales	216	Datos disponibles
Datos para validación	45	Seleccionados al azar
<b>Red-B</b>		
Momento	0.5	Optimización de parámetro (mínimo error de validación)
Neuronas en la capa oculta	18	Optimización de parámetro (mínimo error de validación)
Iteraciones	11000	Optimización de parámetro (mínimo error de validación)

Parámetro	Valor	Criterio de selección
<b>Red-C</b>		
Momento	0.9	Optimización de parámetro (mínimo error de validación)
Neuronas en la capa oculta	18	Optimización de parámetro (mínimo error de validación)
Iteraciones	4000	Optimización de parámetro (mínimo error de validación)
<b>Red-D</b>		
Momento	0.7	Optimización de parámetro (mínimo error de validación)
Neuronas en la capa oculta	28	Optimización de parámetro (mínimo error de validación)
Iteraciones	8000	Optimización de parámetro (mínimo error de validación)

Esta red tiene como salida el  $F_s$  a las 48 horas. El error medio de la red es del 9.5%. Las predicciones son analizadas en las figuras 6.7 y 6.8, en las cuales se muestran el coeficiente de correlación obtenido para las predicciones y la comparación entre los datos reales y las predicciones de la red, respectivamente. El coeficiente de correlación presenta un valor de 0.82, lo cual se considera un buen resultado, teniendo en cuenta la cantidad de datos analizados y las exigencias de la planta. Como era de esperar, esta correlación muestra la relación entre los procesos de floculación, representados por las *cps* totales y las *cps* para partículas entre 10 y 32  $\mu\text{m}$ , y el índice de clase del fibrocemento.

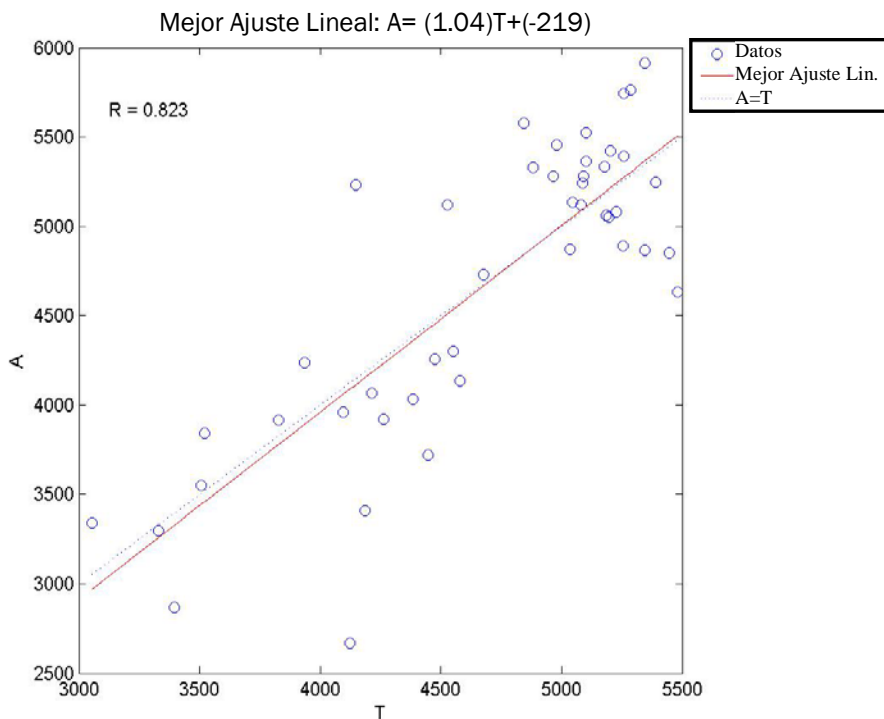


Figura 6.7 – Datos reales frente a datos predichos para el  $F_s$  a las 48 horas. 45 muestras de validación. (A= datos predichos; T= datos reales)  
 Gráfico obtenido con Matlab 6.5 R13 tras el entrenamiento de la red.

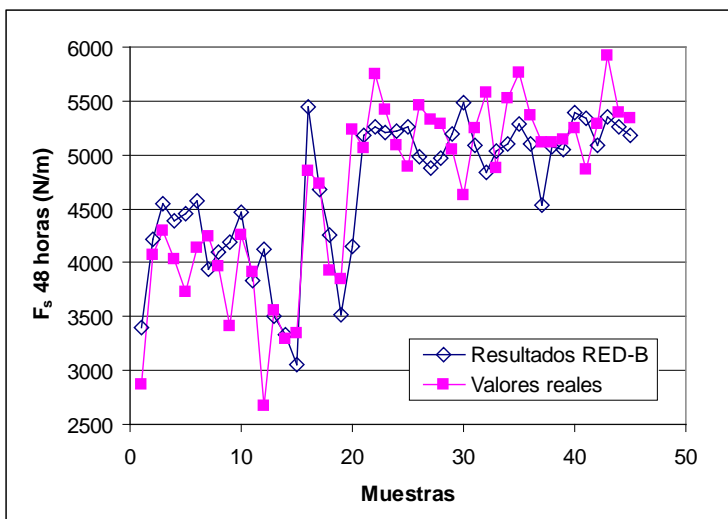


Figura 6.8 – Valores reales y predicciones de la RED-B para las muestras de validación.

La siguiente tarea en la creación de las redes neuronales es la obtención de recomendaciones de la RED-B, con el fin de optimizar el proceso de producción. Como las redes creadas tienen tres entradas, las respuestas se pueden ver en gráficos tridimensionales en los cuales se varían dos de las entradas entre sus valores mínimo y máximo, mientras la tercera se fija en un valor concreto.

En una hoja de papel no se puede variar esta tercera entrada, pero si se considera el tiempo como una escala en la cual variar esa última entrada, se puede tener un vídeo con una superficie tridimensional en movimiento, variando las tres entradas. Analizando estos vídeos, se ha comprobado la validez de las recomendaciones obtenidas, así como su robustez y estabilidad.

Las recomendaciones son intervalos óptimos de valores para cada una de las entradas, las cuales podrán ser empleadas a escala industrial para optimizar el proceso de producción. Estas recomendaciones serán expuestas conjuntamente en su apartado correspondiente.

Como primer resultado se observa una influencia claramente positiva de la densidad en tierno sobre el  $F_s$  a las 48 horas. En la figura 6.9 se representa un gráfico de superficie, para un valor de densidad en tierno máximo de 1.98 kg/L. En la base se representa también un gráfico de contorno. En este gráfico, la zona considerada óptima en las respuestas se encuentra marcada por un círculo. No se debe olvidar que todos estos análisis son de predicciones de redes neuronales, con el error que ello conlleva.

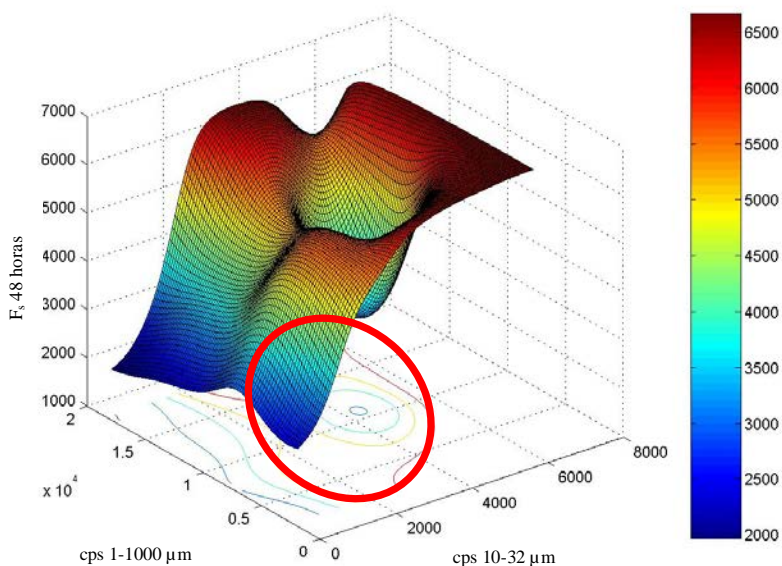


Figura 6.9 – Superficie de respuesta de la RED-1 para el  $F_s$  a las 48 horas.  
(Zona óptima marcada con el círculo) Densidad en tierno = 1.98 kg/L.

### 6.1.3.1.3. Red neuronal “C”

Esta red tiene como salida el  $F_s$  a los 7 días. El error medio de la red es del 8.5%, inferior al de la RED-B. El coeficiente de correlación obtenido para las predicciones y la comparación entre los datos reales y las predicciones de la red se muestran en las figuras 6.10 y 6.11, donde se pueden ver las buenas predicciones obtenidas para esta propiedad. El coeficiente de correlación (0.85) muestra la buena capacidad de predicción de la misma.




Figura 6.10 – Datos reales frente a datos predichos para el  $F_s$  a los 7 días. 45 muestras de validación. (A= datos predichos; T= datos reales)  
 Gráfico obtenido con Matlab 6.5 R13 tras el entrenamiento de la red.

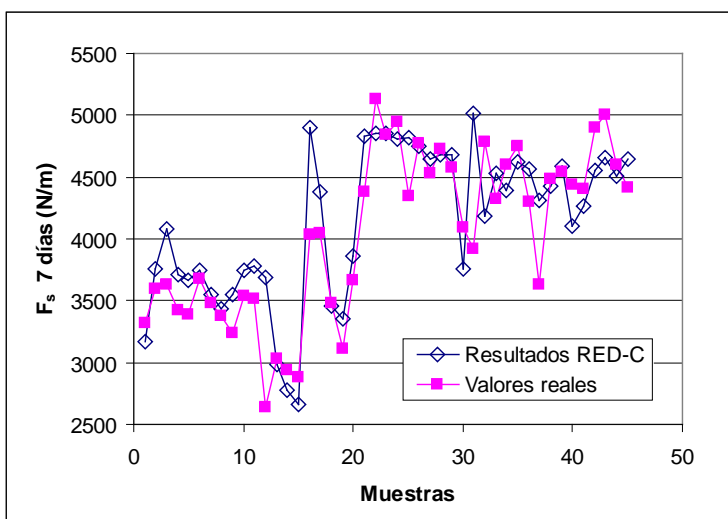


Figura 6.11 – Valores reales y predicciones de la RED-C para las muestras de validación.

Asimismo, se ha realizado para esta red el mismo análisis que en la RED-B. La superficie de respuesta para el valor máximo de densidad en tierno se muestra en la figura 6.12. Se observa de nuevo un efecto positivo de la densidad en tierno sobre el  $F_s$  a los 7 días.




Figura 6.12 - Superficie de respuesta de la RED-C para el  $F_s$  a los 7 días.  
(Zona óptima marcada con el círculo) Densidad en tierno = 1.98 kg/L.

#### 6.1.3.1.4. Red neuronal "D"

Esta red tiene como salida el  $M$  a los 7 días. El error medio de la red es del 11%. El coeficiente de correlación obtenido para las predicciones y la comparación entre los datos reales y las predicciones de la red se muestran en las figuras 6.13 y 6.14. La predicción en este caso no es tan buena como para los índices de clase. De todas formas, el índice de correlación de 0.71 todavía es aceptable, aunque muestra que esta resistencia es más difícil de predecir. En la figura 6.14, se ve que existe mayor diferencia entre las predicciones, que tienden a tener valores medios, más estables, y los ensayos de fábrica, cuyos valores presentan mayor variabilidad.

Una posible explicación a esto residiría en que el espesor de la placa tiene mayor efecto sobre el  $M$  que sobre el  $F_s$ , con lo cual se introduce una variabilidad aleatoria, que justifica que esta predicción sea peor.

La superficie de respuesta para el valor máximo de densidad en tierno se muestra en la figura 6.15. El círculo discontinuo presenta una zona inestable con los cambios de densidad en tierno.

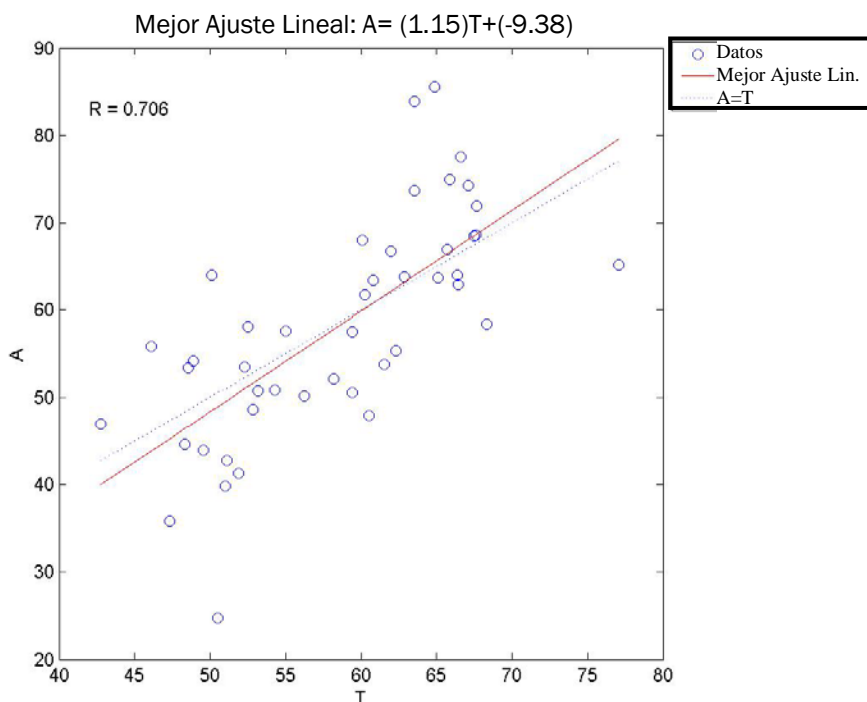


Figura 6.13 – Datos reales frente a datos predichos para el  $M$  a los 7 días. 45 muestras de validación. (A= datos predichos; T= datos reales)

Gráfico obtenido con Matlab 6.5 R13 tras el entrenamiento de la red.




Figura 6.14 - Valores reales y predicciones de la RED-D para las muestras de validación.




Figura 6.15 - Superficie de respuesta de la RED-D para el  $M$  a los 7 días. (Zonas óptimas marcada con círculos) Densidad en tierno = 1.98 kg/L.

### 6.1.3.1.5. Red neuronal "E"

En las redes E y F las entradas son las mismas que para las redes B, C y D, siguiendo el mismo razonamiento en la metodología. Pero en estos casos, las salidas son múltiples, y representan resistencias, espesores y densidades a 48 horas y 7 días. Todas las entradas y salidas de las redes E y F se muestran en la tabla 6.9.

Tabla 6.9 – Entradas y salidas de las redes E y F.

Entradas	Salidas
Número de cuentas por segundo de partículas entre 10 y 32 $\mu\text{m}$ (cps)	$F_s$ a las 48 horas (N/m)
Número de cuentas totales por segundo de partículas (entre 1 y 1000 $\mu\text{m}$ ) (cps)	e a las 48 horas (mm)
Densidad en tierno (kg/L)	$F_s$ a los 7 días (N/m)
	e a los 7 d (mm)
	$M$ a los 7 d (N·m/m)
	$d$ a los 7 días (kg/L)

En estas redes se utiliza el mismo sistema de optimización de parámetros que en las anteriores. En la tabla 6.10 se muestran los parámetros óptimos empleados en la RED-E. Debe recordarse que esta red se realiza únicamente con datos de un tipo de perfil dentro de la fabricación de fibrocemento con fibras de PVA. Esta fabricación recibe el nombre de PVA-A. En la RED-F se realizará el mismo estudio para redes de diferentes perfiles de fabricación.

Tabla 6.10 – Parámetros de la RED-E. Valores y criterios de selección.

Parámetro	Valor	Criterio de elección
Algoritmo de entrenamiento	Retropropagación de tipo descenso de gradiente con factor de aprendizaje variable.	Fijado
Tipo de función de transferencia	Ecuación logística	Fijado
Factor de aprendizaje	Variable (Debido al algoritmo de entrenamiento) Valor inicial = 0.05	Ligado al algoritmo de entrenamiento
Momento	0.7	Optimización de parámetro (mínimo error de validación)
Número de capas ocultas	1	Optimización de parámetro (mínimo error de validación)
Número de neuronas en las capas ocultas	28	Optimización de parámetro (mínimo error de validación)
Número de iteraciones	7000	Optimización de parámetro (mínimo error de validación)
Número de datos totales	139	Datos disponibles
Datos para validación	26	Elegidos al azar

El error medio en esta red es del 10%. Los mejores resultados se obtienen de nuevo, como en la RED-A, para los  $F_s$  a 48 horas y 7 días, y para la densidad a 7 días (ver ejemplo de la figura 6.16).




Figura 6.16 – Datos reales frente a datos predichos para la densidad a los 7 días. 26 muestras de validación. (A= datos predichos; T= datos reales) Gráfico obtenido con Matlab 6.5 R13 tras el entrenamiento de la red.

En la tabla 6.11 se muestran los coeficientes de correlación obtenidos para cada salida de la red neuronal. Se ve claramente que los valores obtenidos para los espesores son claramente peores que el resto. Esto demuestra que la RED-E es capaz de distinguir entre variables predecibles e impredecibles.

Tabla 6.11 – Coeficientes de correlación “R” para cada salida (RED-E).

	48 horas		7 días			
	$F_s$	$e$	$F_s$	$e$	$M$	$d$
Coeficientes R	0.81	0.36	0.80	0.40	0.74	0.81

Se procede a realizar el mismo tipo de análisis que en las redes B, C y D. Se consideran óptimos aquellos valores de las entradas que optimizan los índices de clase y el momento flector.

Con este análisis, evaluando las superficies de respuesta para diferentes valores de la densidad en tierno, tal como se hizo en las redes B, C y D, se tiene un primer resultado bastante claro, que es, como ya se obtuvo en las redes específicas, el efecto positivo de la densidad en tierno sobre los  $F_s$  y el  $M$  del producto final. En la figura 6.17 se puede observar, a modo de ejemplo, la superficie de respuesta para el  $F_s$  a los 7 días.

El círculo discontinuo representa zonas de respuesta buena, pero inestables ante cambios de la densidad en tierno.




Figura 6.17 – Superficie de respuesta de la RED-E para el  $F_s$  a los 7 días.  
(Zonas óptimas marcada con círculos) Densidad en tierno = 1.98 kg/L.

### 6.1.3.1.6. Red neuronal "F"

Esta red neuronal se crea para comprobar la robustez de las conclusiones de la RED-E, añadiendo datos para diferentes perfiles de placas de fibrocemento PVA. Es también una manera de validar la metodología empleada en un intervalo más amplio de aplicación, siempre a escala industrial. También se quiere comprobar la calidad de las predicciones cuando se añaden nuevos datos a la red neuronal. Las entradas y salidas de la red son las mismas que en la RED-E (Ver tabla 6.9).

Se obtendrán recomendaciones separadas para las redes E y F, que servirán para comparar los resultados de la RED-E, obtenida con datos de producción PVA-A, con resultados obtenidos con datos de 4 diferentes perfiles de placas, que son PVA A, B, C y D, empleando la RED-F.

Es necesario aplicar factores de corrección para disponer de datos con valores comparables, ya que en los índices de clase se observan diferencias entre los 4 perfiles analizados. Los factores aplicados se muestran en la tabla 6.12. Estos factores se han calculado con la relación histórica de resistencias entre los distintos perfiles de placas.

Tabla 6.12 – Factores de corrección para el  $F_s$ . PVA-A es el perfil de referencia.

Producción	PVA-A	PVA-B	PVA-C	PVA-D
Factor de corrección	1	0.82	1	1.24

Todos los resultados se analizan como si fuesen únicamente del perfil PVA-A, que es la referencia. Por ejemplo, si se tiene una placa de PVA-B con  $F_s$  a las 48 horas con un valor de 3000 N/m, la entrada a la RED-F debería ser  $3000 / 0.82 = 3659$  N/m. Todos los coeficientes de correlación calculados con las salidas se refieren a placas PVA-A. Los resultados, una vez aplicados a la inversa los factores, podrían aplicarse a los diferentes perfiles.

En la optimización de parámetros de la RED-F se ha aprovechado la experiencia previa obtenida con la RED-E, con la que se observó que el empleo de redes neuronales con más de una capa oculta no suponía ninguna ventaja, con lo que no se estudian estas redes en la optimización. Los valores óptimos de los

distintos parámetros se muestran en la tabla 6.13. Algunos valores coinciden con los de la RED-E. Este hecho es posible debido a que el proceso presenta la misma naturaleza, y los parámetros óptimos de la red neuronal dependen del proceso, entre otras variables.

El error medio de la red es del 11%, teniendo este error el mismo significado que en anteriores redes. En general, la capacidad de predicción ha disminuido ligeramente, pero si se analiza este descenso variable de salida a variable de salida (cuyos coeficientes de correlación se pueden ver en la tabla 6.14), se puede observar un gran descenso de la calidad de las predicciones de los espesores. El resto disminuyen ligeramente, pero los  $F_s$  tanto a 48 horas como a 7 días (ver figura 6.18 como ejemplo de resultados) aumentan su calidad de predicción de forma apreciable.

Tabla 6.13 – Parámetros de la RED-F. Valores y criterios de selección.

Parámetro	Valor	Criterio de elección
Algoritmo de entrenamiento	Retropropagación de tipo descenso de gradiente con factor de aprendizaje variable.	Fijado
Tipo de función de transferencia	Ecuación logística	Fijado
Factor de aprendizaje	Variable (Debido al algoritmo de entrenamiento) Valor inicial = 0.05	Ligado al algoritmo de entrenamiento
Momento	0.7	Optimización de parámetro (mínimo error de validación)
Número de capas ocultas	1	Fijado (por experiencia previa)
Número de neuronas en las capas ocultas	28	Optimización de parámetro (mínimo error de validación)
Número de iteraciones	11000	Optimización de parámetro (mínimo error de validación)
Número de datos totales	216	Datos disponibles
Datos para validación	45	Elegidos al azar

Teniendo en cuenta el tratamiento de los datos, realizando medias de intervalos de 10 minutos previos a cada medida del sensor FBRM, y la aplicación de factores de corrección, que podrían haber hecho bajar la calidad de las predicciones debido a los errores arrastrados, se puede considerar que las predicciones presentan una calidad muy aceptable. Se han empleado 45 datos de validación para comprobar que esta red es una gran herramienta de predicción de resistencia del fibrocemento a escala industrial.

Tabla 6.14 – Coeficientes de correlación “R” para cada salida (RED-F).

	48 horas		7 días			
	$F_s$	$e$	$F_s$	$e$	$M$	$D$
Coeficientes R	0.82	0.48	0.88	0.14	0.68	0.75




Figura 6.18 – Valores reales y predicciones de la RED-F para las muestras de validación.

Un ejemplo del análisis de superficie de respuesta se muestra en la figura 6.19.




Figura 6.19 – Superficie de respuesta de la RED-F para el  $F_s$  a los 7 días.  
(Zona óptima marcada con un círculo) Densidad en tierno = 1.98 kg/L.

### 6.1.3.2. Recomendaciones obtenidas

Las recomendaciones se han dividido en tres grupos: el de las redes B, C y D, el de la RED-E, y el de la RED-F. En todos los grupos se tiende a considerar óptimos los intervalos que maximizan a la vez las respuestas de los índices de clase a 48 horas y 7 días y el momento flector a 7 días.

#### REDES B, C y D

Las recomendaciones se obtienen en este caso analizando simultáneamente las tres redes. Se consideran intervalos óptimos aquellos en los

que todas las respuestas presentan valores elevados y estables a los cambios. Siguiendo este criterio, se han obtenido las siguientes recomendaciones:

- Cuanto mayor es la densidad en tierno, mayores son los valores de resistencia del producto final.
- Las cuentas totales por segundo (entre 1 y 1000  $\mu\text{m}$ ) han sido estudiadas en el intervalo entre 2322 y 18295. Los valores óptimos son, en general, los mínimos, debido a su estabilidad. Pero si se tienen valores de las cps de partículas entre 10 y 32  $\mu\text{m}$  por encima de 2000 cps, los valores óptimos del número total de cuentas por segundo solo dependen en pequeña medida de la densidad en tierno.
- Las cuentas por segundo de partículas entre 10 and 32  $\mu\text{m}$ , se estudian en el intervalo entre 123 y 6327. Los valores óptimos son aquellos por encima de 2000 cps, y cuanto mayor es el valor, más estables resultan las respuestas de las redes. Cabe destacar que, en este estudio, con valores elevados de la densidad en tierno y cps de partículas entre 10 y 32  $\mu\text{m}$  por encima de 2000 cps, el número total de cuentas por segundo puede tener cualquier valor, ya que todas las respuestas son buenas en esta situación.

## RED-E

Para la RED-E las recomendaciones son las siguientes:

- Cuanto mayor es la densidad en tierno, mayores son los valores de resistencia del producto final.
- Las cuentas totales por segundo (entre 1 y 1000  $\mu\text{m}$ ) han sido estudiadas en el intervalo entre 4875 y 18295. Los valores óptimos son, en general, los mínimos, pero se pueden variar, jugando con los valores de las cps de partículas entre 10 y 32  $\mu\text{m}$ , siempre que no se salga de las zonas óptimas evaluadas en las superficies de respuesta (ver los círculos de la figura 3.12, mostrada como ejemplo).
- Las cuentas por segundo de partículas entre 10 y 32  $\mu\text{m}$ , se estudian en el intervalo entre 586 y 6327. Los valores óptimos se

encuentran alrededor de 2000-3000 cps, y cuanto mayor es el valor, más estables resultan las respuestas de las redes. Siguiendo las zonas óptimas de respuesta, el valor óptimo puede incrementarse ligeramente según lo hacen las cuentas totales por segundo.

## RED-F

Las recomendaciones obtenidas para la RED-F son las siguientes:

- Cuanto mayor es la densidad en tierno, mayores son los valores de resistencia del producto final (igual que en todas las redes analizadas).
- Las cuentas totales por segundo (entre 1 y 1000  $\mu\text{m}$ ) han sido estudiadas en el intervalo entre 2322 y 18295. Los valores óptimos son, en general, los mínimos, pero se pueden variar, jugando con los valores de las cps de partículas entre 10 y 32  $\mu\text{m}$ , siempre que no se salga de las zonas óptimas evaluadas en las superficies de respuesta (ver el círculo de la figura 3.14, mostrada como ejemplo).
- Las cuentas por segundo de partículas entre 10 y 32  $\mu\text{m}$ , se estudian en el intervalo entre 123 y 6327. Los valores óptimos se encuentran alrededor de 2000-3000 cps y, una vez más, cuanto mayor es el valor, más estables resultan las respuestas de las redes. Cabe destacar, igual que en la RED-E, que con valores elevados de la densidad en tierno y de las cuentas por segundo de partículas entre 10 y 32  $\mu\text{m}$  por encima de 2000, el número total de cuentas por segundo puede tener cualquier valor, ya que todas las respuestas son buenas en esta situación.

## **6.2. PRODUCCIÓN DE PAPEL**

La producción de papel es un proceso que en la actualidad se encuentra bien controlado. Como se ha indicado, en el caso de la fábrica seleccionada para la aplicación de los modelos matemáticos en el sector papelerero (HPM), se cuenta con gran cantidad de datos accesibles a través del sistema WinMOPS de adquisición de datos. Éstos se emplearán para encontrar correlaciones entre los diferentes parámetros de proceso y de producto, así como para la construcción de modelos matemáticos que serán empleados para el control predictivo y adaptativo de los procesos. Asimismo se han considerado en los procesos de modelado otros datos procedentes de fuentes externas como datos tomados a mano y datos de sensores instalados en la máquina, pero que no están conectados al WinMOPS, como por ejemplo el sensor FBRM instalado en línea, que se ha utilizado para la optimización de la parte húmeda de la máquina de papel.

Por tanto, si en la aplicación a la industria del fibrocemento se disponía de una cantidad bastante limitada de datos, en este caso la disponibilidad de datos es abrumadora, debido a que la fábrica seleccionada para la realización de las investigaciones es una de las más modernas de Europa.

### **6.2.1. Optimización de la calidad del papel**

Aunque existen variables físico-químicas que se pueden medir directamente con la tecnología actual, y pueden ser fácilmente controladas, existen también fenómenos más complejos que resultan difíciles de controlar y que presentan una influencia importante sobre la manejabilidad de la máquina, la calidad del producto, los consumos de agua o energía, etc. Estos fenómenos, entre los que se incluye la floculación, se suelen controlar en la actualidad mediante la monitorización de las propiedades del producto final, lo que conlleva un importante retraso desde la detección de un problema a la ejecución en el sistema de los cambios necesarios.

De hecho, debido a la complejidad del sistema, las acciones correctivas han de ser iterativas: una vez se ha medido una desviación en la calidad del producto final o en los parámetros del proceso que controlan estos fenómenos, la vuelta a unas condiciones de operación aceptables o a unas especificaciones de producto concretas tiene lugar en numerosos pasos. Si a esto se le une las elevadas velocidades de producción que se manejan en una fábrica actual (mayores de 1800 m/min en el caso del papel prensa), es entendible que durante el periodo de

regulación se habrán producido grandes cantidades de papel que no cumple las especificaciones deseadas.

El mecanismo de floculación que tiene lugar en la parte húmeda de la máquina de papel determinará las propiedades de los flóculos en la formación de la hoja y, por tanto, influirá sobre la retención, el drenaje y la formación de la hoja. Ello implica que tendrá una gran influencia sobre la manejabilidad de la máquina y las propiedades finales del producto.

La ya citada calidad del producto se torna crucial cuando el usuario decide la opción más acorde a sus necesidades. El papel gráfico de baja calidad, estudiado en la presente tesis, presenta propiedades importantes desde ese punto de vista, como son la densidad, el brillo, el color, la suavidad de la superficie, la capacidad de absorción de aceites y la resistencia (tracción y desgarro). Por tanto, debido a la complejidad del sistema y los objetivos a conseguir, las técnicas avanzadas de control resultan de gran ayuda.

### **6.2.1.3. Procesado previo de los datos**

Se distinguen diferentes tareas en esta etapa, que se describen a continuación.

#### ***Conversión de los datos***

Los datos empleados han sido tomados de diferentes fuentes. Los datos procedentes de WinMOPS y del sensor FBRM deben ser recogidos y guardados de tal forma que puedan ser fácilmente implementados en Matlab, que es el programa empleado para el análisis y modelado, como ya se explicó en la sección de materiales y métodos.

La primera dificultad surgió al no disponer de una herramienta que permitiese la exportación de datos directamente de WinMOPS a Matlab o KCL-Wedge, otro programa de análisis probado en una primera fase de la investigación. Por tanto, fue necesario desarrollar dos alternativas de programas de conversión, cuyo objetivo es el de crear archivos de texto válidos para la importación de estos datos en Matlab. Ambas alternativas fueron comparadas según se muestra a continuación.

1. *Programas que convierten los datos a través de archivos ASCII:* Éstos convierten directamente datos tomados de la base de datos de WinMOPS en un archivo ASCII importable mediante KCL-Wedge o Matlab, según se observa en la Figura 6.20.

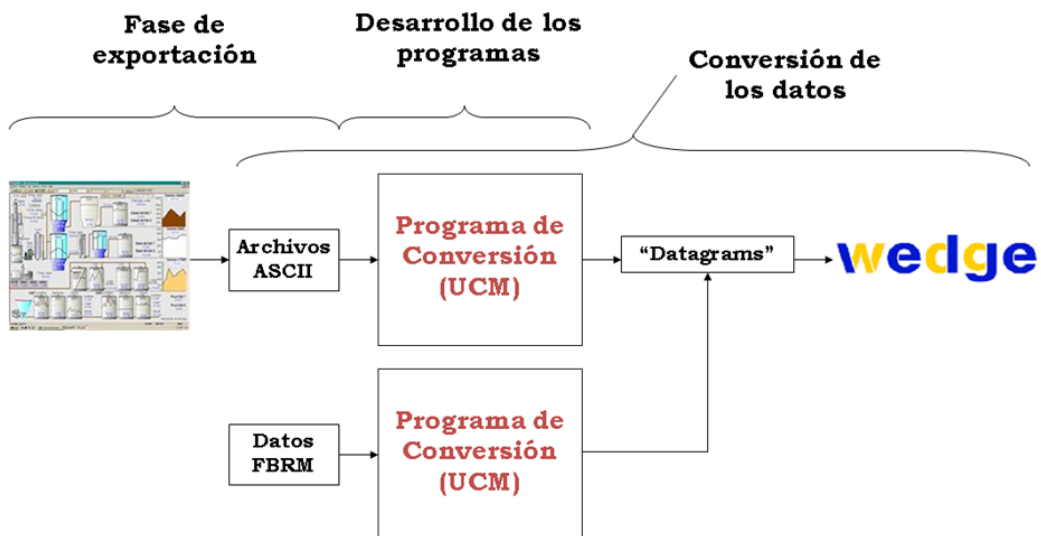


Figura 6.20 – Esquema de conversión de los datos de WinMOPS a KCL-Wedge, a través de ficheros ASCII.

En este caso al tomarse los datos directamente de la base de datos, se transforman todos los datos recogidos. Por tanto es necesario procesarlos previamente con el sistema WinMOPS, que permite aislar datos erróneos por su “status” (Clasificación que WinMOPS emplea para señalar diferentes problemas en la adquisición de datos).

Un factor fundamental en la comparación entre ambas alternativas fue el tiempo estimado necesario para importar los archivos con KCL-Wedge, entre 1 y 2 meses debido a sobrecargas en el “buffer” o almacén temporal de memoria volátil de equipos gestionados con Windows XP, lo que hizo descartar esta forma de trabajo en las etapas de modelado. Se tuvo también en cuenta para la decisión el hecho de que, al emplear medidas externas al sistema WinMOPS, como son los datos del sensor FBRM, hacía falta otro programa para la unión de ambas fuentes en un archivo único con fechas sincronizadas.

2. *Programas que convierten los datos de WinMOPS y del sensor FBRM a través de hojas de Excel con fechas escalonadas constantemente:* Con esta opción, los datos se recogen y filtran mediante archivos de Excel, para ser posteriormente transferidos a KCL-Wedge o a Matlab, según se observa en la Figura 6.21.

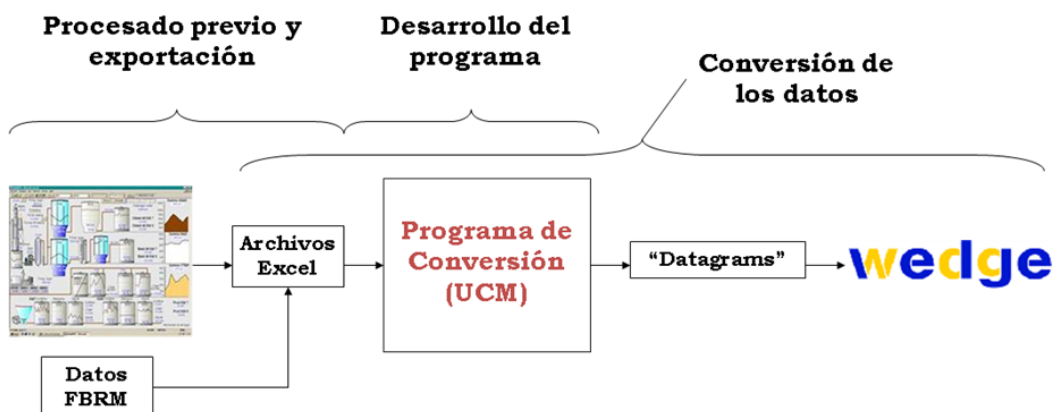


Figura 6.21 - Esquema de conversión de los datos de WinMOPS a KCL-Wedge, a través de archivos de Excel.

La principal ventaja se observó en el momento de convertir las hojas de Excel a archivos ASCII, que llevó entre 1 y 2 días aproximadamente, al no sobrecargarse el almacén temporal de memoria de la misma forma que en el caso anterior. Ello supuso una gran ventaja a la hora de afrontar la creación de diferentes modelos incluyendo diferentes variables. Ha de tenerse en cuenta que este sistema no sería adecuado si se estudiaran fenómenos muy rápidos, ya que se evalúan medias móviles de los datos cada 5 minutos.

Por tanto, esta segunda opción fue la elegida, ya que se buscaban predicciones a medio plazo, y no fenómenos puntuales. Se crearon hojas de Excel automatizadas, con fechas escalonadas cada cinco minutos.

**Selección del tipo de papel**

En una fábrica de papel, aunque se considere una sola máquina de papel, se producen diferentes tipos de producto. Un ejemplo de la variedad de la producción se ve en la tabla 6.15 o en la figura 6.22. En el caso expuesto la selección de datos se realizó con el programa KCL-Wedge.

Los distintos tipos de papel se han convertido en números enteros para su visualización y filtrado automático como una variable más. En la tabla 6.15 se observa que los tres papeles prensa suponen la gran mayoría de los datos.

Tabla 6.15 – Tipos de papel producidos en Julio, Agosto y Septiembre de 2004.

Marca de tipo	Tipo de papel	% de datos	Nº de datos
1	Prensa 45.0	61	11410
2	Prensa 42.5	15	2796
3	Prensa 48.8	9.6	1792
4	Prensa Mejorado 48.8 A	0.63	118
5	Prensa Mejorado 48.8 B	3.8	704
6	LWC 60.0	6.3	1176
7	LWC 65.0	1.1	206
8	LWC 57.0	2.3	420
9	Otros	0.091	17
<b>Total</b>			<b>18639</b>




Figura 6.22 – Gráfico de tendencia del tipo de papel vs. tiempo. Los distintos tipos de papel se numeran según tabla 6.15.

Dependiendo del estudio a realizar, se podrían considerar diferentes tipos de papel, siguiendo el mismo procedimiento varias veces y guardando los resultados en archivos distintos. Esta herramienta resulta de gran utilidad, ya que una fábrica de papel suele presentar necesidades diferentes para cada tipo de producción, que pueden ser analizados independientemente.

Dependiendo de la cantidad de datos disponibles, se puede decir que en la mayoría de los casos bastará con aplicar un autofiltro en una hoja de Excel, sin necesidad de recodificar los nombres de cada tipo de papel, ya que los tipos de papel "Prensa 45.0", "Prensa 42.5" y "Prensa 48.8" representan la mayoría de los datos totales (ver tabla 6.15) y, por tanto, han sido los tipos seleccionados para los análisis más detallados, no requiriéndose un filtro más complejo en esta etapa.

Esta tesis se ha centrado por tanto en la producción de papel prensa estándar, con lo que el resto de tipos de papel han sido eliminados. La secuencia de eliminación mediante KCL-Wedge se muestra en la figura 6.23. Se realiza una elección del intervalo válido de valores, eliminando el resto y representando el gráfico de tendencia sin los datos eliminados (figura 6.24), con líneas verticales grises en los periodos eliminados.

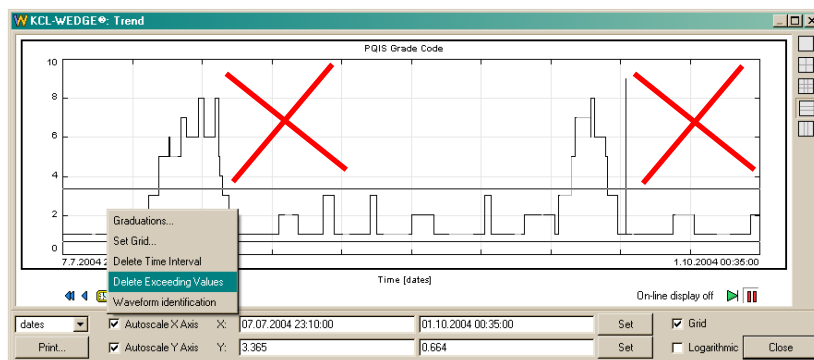


Figura 6.23 – Proceso de selección del tipo de papel.  
Los valores elegidos se muestran entre las dos líneas horizontales.

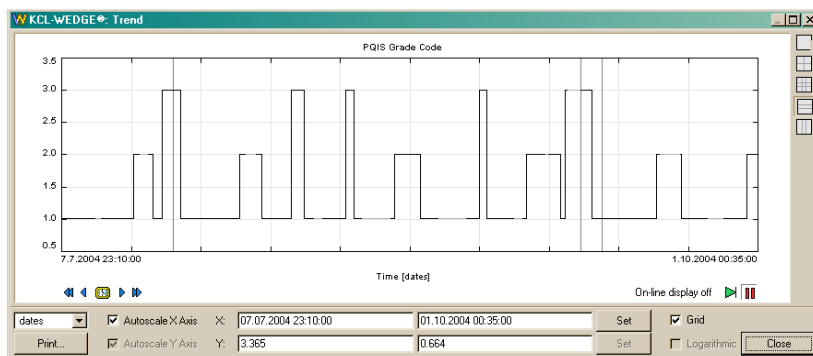


Figura 6.24 – Nuevo gráfico de tendencia tras la eliminación.

Los datos tomados con el sensor FBRM se han incorporado a los datos de fábrica en los modelos creados. Se pretende con ello evaluar la mejora de la robustez de los resultados y evaluar el impacto de la distribución de tamaños de partícula sobre los parámetros de calidad estudiados.

Este punto resultará de una gran utilidad práctica ya que, en el caso de demostrarse, como se verá más adelante, que este sistema de medida aporta información valiosa, con la experiencia adquirida en su manejo y en la creación de modelos con sus medidas, se podría recomendar su adquisición a fábricas de menor tamaño que quisieran incorporar en su sistema un único aparato de medida que les fuese lo más útil posible.

### ***Filtrado de datos***

Esta última etapa dentro del procesado previo incluye más pasos de filtrado de datos, no considerados anteriormente. El objetivo es considerar solo aquellos datos que representen fielmente los fenómenos que ocurren en fábrica y que se desean modelar. Por ello las etapas de filtrado son flexibles, y dependen de cada problema específico, pudiéndose incluso obviar algunas de ellas. Los datos que más comúnmente suelen filtrarse son:

1. *Paradas y arranques de máquina.*
2. *Periodos de roturas.* En el caso del presente estudio, donde se intenta modelar el comportamiento de la máquina en condiciones normales, estos datos han sido descartados.
3. *Producción fuera de especificaciones.* Algunas de las bobinas producidas pueden encontrarse fuera de especificaciones. En este caso también han sido eliminados los datos correspondientes, debido a que no muestran el comportamiento normal de la máquina.
4. *Datos anormales.* En este último paso del filtrado de datos se descartan todos aquellos que presentan valores poco comunes. Se ha procedido a eliminar colas automáticamente a  $\pm 3\sigma$  en los casos asimilables a distribuciones gaussianas o normales. Resulta también de gran ayuda la evaluación de histogramas (figura 6.25) para la comprobación de aquellos valores, muchas veces debidos a anomalías en la toma de datos por fallo de los medidores. En este caso, la etapa de filtrado ha sido liviana, debido al filtrado previo según la variable “status” de WinMOPS.

El primer filtrado realizado con el papel tipo “Prensa 45.0” ha supuesto el establecimiento de valores aceptables de las variables de proceso mediante el análisis de la distribución de los datos analizados mediante histogramas de frecuencia.

En este estudio solo se han filtrado aquellos datos absurdos, como los flujos negativos. Otro punto a tener en cuenta, aunque se analizará posteriormente, es que las entradas a los modelos han de ser lo menos dependientes posible, para tener un espacio multidimensional de trabajo apropiado y, por lo tanto, lo más ortogonal posible.

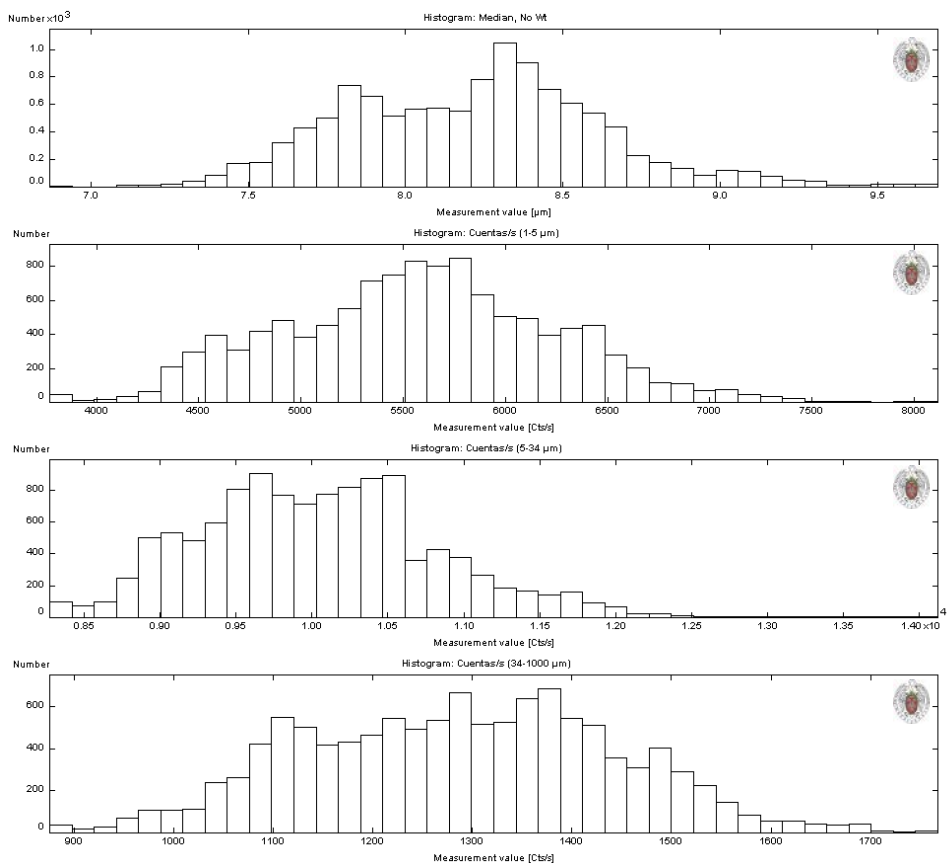


Figura 6.25 – Ejemplos de histograma para algunas de las variables seleccionadas, tomadas con el sensor FBRM.

En algunos casos el análisis de componentes principales (PCA) constituye una herramienta útil para obtener esta ortogonalidad. Esta técnica podría ser útil únicamente en casos en los que la optimización del proceso no sea uno de los objetivos, ya que complica la interpretación de los resultados. En cambio, si está presente dicha optimización, lo que se busca es tener modelos con un número muy reducido de variables de proceso. Este tipo de modelos reducidos presenta dos ventajas en estos casos: la primera es que el personal de fábrica prefiere actuar sobre el mínimo número de variables de proceso posibles, aunque se disponga de un gran modelo con numerosas entradas, y la segunda es que actuar sobre numerosas variables en la fase de optimización resulta una tarea prácticamente imposible, debido a la dependencia siempre presente entre algunas de ellas.

### 6.2.2. Primera selección de variables

Esta etapa suele estar determinada por los objetivos del estudio y la experiencia del personal de fábrica y de los investigadores involucrados en el estudio. En algunos casos, esta selección ha de ser muy vasta con el fin de encontrar todas las influencias posibles sobre las funciones objetivo (en este caso, parámetros de la calidad del producto), y seleccionar aquellas más significativas en etapas posteriores a partir de los modelos desarrollados y analizados, con una segunda reducción del número de variables.

El objetivo en este caso es optimizar la parte húmeda de la máquina de papel mediante la predicción de la calidad del papel. Por tanto, la primera selección ha de tener en cuenta únicamente las variables de proceso relacionadas con el final de la parte húmeda, consideradas influyentes y fiables por el personal de fábrica. La selección puede observarse en la tabla 6.16. Adicionalmente a las variables adquiridas en fábrica, se han unido datos del sensor FBRM instalado en la fábrica, pero separado del sistema WinMOPS.

Tabla 6.16 – Variables elegidas tras la primera selección. En rojo medidas de la calidad del papel, y en azul, medidas del sensor FBRM.

VARIABLE	UNIDS.	VARIABLE	UNIDS.
Cons. Caja Entrada (DCS) PM61	g/l	Gramaje (PaperLab) PM61	g/m <sup>2</sup>
Cons. Caja Entrada (Lab) PM61	%	Espesor (PaperLab) PM61	µm
Cenizas caja entrada (DCS) PM61	g/l	Índice Formación (PaperLab) PM61	
Cenizas caja entrada (Lab) PM61	%	Rcia. Tracción (PaperLab) PM61	kN/m
Cons. Ag. Blancas (DCS) PM61	g/l	Rcia. Desgarro (PaperLab) PM61	Nm <sup>2</sup> /kg
Cons. Ag. Blancas (Lab) PM61	%	Elongación (PaperLab) PM61	
Cenizas Ag. Blancas (DCS) PM61	g/l	Densidad (PaperLab) PM61	kg/m <sup>3</sup>
Cenizas Ag. Blancas (Lab) PM61	%	Hand (PaperLab) PM61	cm <sup>3</sup> /g
Retención total (DCS) PM61	%	Longitud de rotura (PaperLab) PM61	km
Retención total (Lab) PM61	%	Long. TEA (PaperLab) PM61	J/m <sup>2</sup>
Retención cenizas (DCS) PM61	%	Longitudinal TSI (PaperLab ) PM61	kNm/g
Retención cenizas (Lab) PM61	%	Transversal TSI (PaperLab) PM61	kNm/g
Índice de floculación PM61		Porosidad (PaperLab) PM61	ml/min
Destintado2 Caudal	m <sup>3</sup> /n	Opacidad (PaperLab) PM61	%
Destintado3 Caudal	m <sup>3</sup> /h	Brillo (PaperLab) PM61	%
Caudal rotos	m <sup>3</sup> /h	Humedad en parte final de PM61	%
Dosis floculante PM61	g/Ton	Cenizas base en papel PM61	%
Dosis coagulante PM61	g/Ton	Cenizas en parte final de PM61	%
Dosis micropartícula PM61	g/Ton	Humedad en Prensa PM61	%
Dosis CaCO <sub>3</sub> PM61	l/h	cps (1-5 µm)	Cts/s
Velocidad cable PM61	m/min	cps (5-34 µm)	Cts/s
pH en PIT		cps (34-1000 µm)	Cts/s
		Media, 1/Lin Pond.	µm
		Media, Cuad. Pond.	µm
		Mediana.	µm
		%<5.41	%
		%>34.15	%

En este caso, debido al gran número de variables seleccionadas y a la cantidad de datos disponibles, se propuso una segunda reducción en esta etapa, teniendo en cuenta experiencias previas mediante análisis estadísticos clásicos. El grupo final de variables elegidas ha sido, por tanto, el siguiente:

- *Variables de entrada:*
  - o Datos de FBRM:
    - Mediana de la distribución de tamaños de cuerda (Mediana, No Wt).
    - Cuentas por segundo 1-5  $\mu\text{m}$ .
    - Cuentas por segundo 5-34  $\mu\text{m}$ .
    - Cuentas por segundo 34-1000  $\mu\text{m}$ .
  - o Velocidad en máquina, dada como velocidad en rodillo principal.
  - o Consistencia de la pasta en la caja de entrada.
  - o Contenido en cenizas de la pasta en la caja de entrada.
  - o Caudal de pasta destintada (Destintado2).
  - o Caudal de pasta destintada (Destintado3).
  - o Caudal de rotos.
  - o Adición de floculante.
  - o Adición de coagulante.
  - o Adición de micropartícula.
  - o Adición de carbonato cálcico.
  
- *Variables de salida:*
  - o Índice de formación.
  - o Resistencia a la tracción.
  - o Elongación.
  - o Resistencia al desgarro.
  - o Contenido de cenizas en parte final de la máquina.

### **6.2.3. Análisis estadístico**

En esta etapa se buscan las correlaciones existentes entre las distintas variables analizadas. El objetivo es encontrar grupos de variables fuertemente relacionadas con el fin de reducir su presencia en el modelo final, y evitar resultados

erróneos debidos a la dependencia entre variables de entrada, o problemas en la convergencia del error de validación.

En la tabla 6.17 se muestra un ejemplo de matriz de correlaciones, con los coeficientes de correlación señalados con fondos distintos según su valor. Con esta herramienta se pueden ver grupos de variables altamente correlacionadas, así como comprobar la adecuación de las entradas a un modelo de predicción de la calidad del papel.

Se han realizado otros análisis dentro de esta etapa, como filtrados  $\pm 3\sigma$  de los datos, siendo  $\sigma$  la desviación estándar, para eliminar aquellos datos estadísticamente alejados del comportamiento habitual, que es lo que se desea predecir. Se podrían realizar dependiendo del caso:

- Análisis de covarianza, que es un modelo lineal general con una variable cuantitativa y uno o más factores, que se emplea para evaluar la dependencia entre variables, eliminando el efecto de regresión lineal múltiple.
- Test del factor “T” de Student, que sirve para comparar dos poblaciones de naturaleza aleatoria, y evaluar si su media es significativamente distinta.
- Test del factor “F” de Snedecor, basado en la distribución de probabilidad continua, para evaluar si dos variables son estadísticamente independientes.
- Filtrados de distribución de datos con otra amplitud, como un filtrado  $\pm 2\sigma$ , con el fin de centrarse en unos intervalos de operación más concretos, dependiendo de los objetivos definidos.

Estos filtros se emplean según los objetivos marcados, el tipo y cantidad de datos disponibles y el intervalo a estudiar.

Tras estos pasos, se procede a evaluar la distribución en el tiempo de los datos seleccionados, con el fin de evitar que determinados periodos de tiempo tengan influencia excesiva en el modelado. Este paso resulta crucial con pequeñas cantidades de datos.

En el presente análisis se ha considerado que la distribución de los datos es correcta y, en consecuencia, no se han aplicado filtros estadísticos adicionales.



#### **6.2.4. Propuesta de técnicas de modelado**

Como ya se ha indicado, en este caso, el comportamiento de la parte húmeda de la máquina de papel no es conocido al nivel de poder elaborar modelos físico-químicos, y al mismo tiempo los objetivos marcan la creación de modelos válidos para intervalos amplios de tiempo. Esta situación hace que se haya elegido el tercer tipo de modelos, comenzando por los más sencillos y conocidos, que fueron las regresiones múltiples.

##### **6.2.4.1. Regresiones múltiples mensuales**

Esta primera técnica no conllevó la elección de un único tipo de producción de papel, ya que los resultados fueron útiles por separado en otros estudios.

Para cada caso se han empleado dos modelos de regresión distintos: uno de ellos sencillo, y el otro conteniendo un factor constante ( $K$  en las tablas), que se emplea para reflejar todas las situaciones no tenidas en cuenta por el modelo sencillo. Como se han empleado 14 variables de entrada, el primero ha proporcionado otros tantos valores de parámetros, mientras que el segundo ha proporcionado 15.

Los coeficientes de correlación y parámetros de los modelos fueron obtenidos por validación aleatoria con datos del mismo periodo que aquellos empleados en la construcción del modelo. Los resultados muestran que dichos coeficientes han cambiado significativamente de un mes a otro, lo cual hace necesario el validar el modelo para cada caso específico. Se han encontrado muy buenas correlaciones para diferentes periodos de tiempo, como se puede observar en la tabla 6.18 para cada mes y cada tipo de producción.

Se ha observado que:

- El coeficiente de correlación para un tipo de papel específico y un modelo concreto ha cambiado drásticamente según el periodo de tiempo empleado para el análisis.
- Todos los modelos con factor  $K$  constante presentan lógicamente mejores coeficientes de correlación que los que no incluyen el factor.
- La producción de papel estucado ligero tipo *LWC 60.0* proporciona, en general, muy buenas correlaciones, excepto para la elongación.

Tabla 6.18 – Coeficientes de correlación de los modelos creados según mes y tipo de producción.

CON K	JULIO				AGOSTO			
	NP42.5	NP45.0	NP48.8	LWC 60,0	NP42.5	NP45.0	NP48.8	LWC 60,0
ÍNDICE DE FORMACIÓN	-	0.76	0.77	0.82	0.87	0.44	0.68	-
RCIA. TRACCIÓN	-	0.63	0.63	0.52	0.46	0.39	0.54	-
QCS FINAL CONT. CENIZAS	-	0.39	0.69	0.7	0.42	0.43	0.8	-
ELONGACIÓN	-	0.34	0.72	-	0.88	0.6	0.89	-
RCIA. DESGARRO	-	0.39	0.78	0.62	0.51	0.4	0.64	-

SIN K	JULIO				AGOSTO			
	NP42.5	NP45.0	NP48.8	LWC 60,0	NP42.5	NP45.0	NP48.8	LWC 60,0
ÍNDICE DE FORMACIÓN	-	0.75	0.67	0.82	0.87	0.37	0.68	-
RCIA. TRACCIÓN	-	0.62	0.61	0.52	0.45	0.29	0.54	-
QCS FINAL CONT. CENIZAS	-	0.35	0.69	0.68	0.36	0.43	0.78	-
ELONGACIÓN	-	0.34	0.72	-	0.88	0.58	0.88	-
RCIA. DESGARRO	-	0.39	0.77	0.59	0.5	0.4	0.63	-

CON K	JULIO				AGOSTO			
	NP42.5	NP45.0	NP48.8	LWC 60,0	NP42.5	NP45.0	NP48.8	LWC 60,0
ÍNDICE DE FORMACIÓN	0.94	0.69	-	-	0.58	0.42	-	0.76
RCIA. TRACCIÓN	0.53	0.58	-	-	0.52	0.54	-	0.69
QCS FINAL CONT. CENIZAS	0.55	0.56	-	-	0.55	0.3	-	0.9
ELONGACIÓN	0.57	0.39	-	-	0.83	0.62	-	0.3
RCIA. DESGARRO	0.81	0.33	-	-	0.52	0.26	-	0.77

SIN K	JULIO				AGOSTO			
	NP42.5	NP45.0	NP48.8	LWC 60,0	NP42.5	NP45.0	NP48.8	LWC 60,0
ÍNDICE DE FORMACIÓN	0.94	0.69	-	-	0.55	0.4	-	0.75
RCIA. TRACCIÓN	0.45	0.58	-	-	0.49	0.5	-	0.66
QCS FINAL CONT. CENIZAS	0.55	0.53	-	-	0.51	0.3	-	0.89
ELONGACIÓN	0.57	0.39	-	-	0.81	0.62	-	0.28
RCIA. DESGARRO	0.81	0.32	-	-	0.51	0.25	-	0.75

Se han observado grandes diferencias cuando se validan los modelos con datos de periodos de tiempo distintos, lo cual implica la poca capacidad de generalización de los modelos creados. No obstante, se probó aplicar el modelo creado con datos de un mes para predecir situaciones de otro mes. Los resultados, que se muestran en la figura 6.26, no han sido lo suficientemente buenos como para continuar empleando estos modelos.




Figura 6.26 – Modelo del índice de formación de Agosto, datos de laboratorio y validación del modelo de Julio en Agosto (2004).

#### 6.2.4.2. Regresión múltiple de cuatro meses

Como el intento de crear regresiones múltiples mensuales no ha resultado satisfactorio, se ha recurrido a aplicar la misma técnica con datos de entrada al modelo desde Julio hasta Octubre de 2004, con el fin de evaluar la calidad de las predicciones y comprobar si algunos valores elevados del índice de correlación vistos en los modelos mensuales eran simplemente una casualidad, o debidos a una buena capacidad de predicción del modelo.

Este tipo de modelo se ha construido únicamente para los dos tipos de papel más producidos en el periodo estudiado, que fueron los papeles *Prensa 45.0* y *Prensa 42.5*. La tabla 6.19 resume todos los coeficientes de correlación

obtenidos. Se muestran los valores medios de correlación obtenidos en cada mes por separado, con las regresiones mensuales, para comparar la precisión del modelo.

Como se puede observar, estos modelos solamente han proporcionado resultados aceptables en el caso de la predicción del índice de formación, mayoritariamente con datos de papel *Prensa 45.0*. Por tanto, este modelo se considera una herramienta útil únicamente para esa variable.

Tabla 6.19 – Coeficientes de correlación del periodo completo, comparados con los valores medios de correlación de cada mes por separado.

	Prensa 42.5			
	Correlación 4 meses		Valor medio mes a mes	
	Con K	Sin K	Con K	Sin K
Índice de Formación	0.84	0.84	0.80	0.79
Rcia. Tracción	0.41	0.41	0.50	0.46
QCS Cont. Cenizas en Final Máquina	0.36	0.33	0.51	0.47
Elongación	0.55	0.52	0.76	0.75
Rcia. Desgarro	0.50	0.49	0.61	0.61

	Prensa 45.0			
	Correlación 4 meses		Valor medio mes a mes	
	Con K	Sin K	Con K	Sin K
Índice de Formación	0.59	0.59	0.58	0.55
Rcia. Tracción	0.47	0.47	0.53	0.50
QCS Cont. Cenizas en Final Máquina	0.23	0.14	0.42	0.40
Elongación	0.34	0.33	0.49	0.48
Rcia. Desgarro	0.40	0.36	0.34	0.34

Tras el análisis de los resultados obtenidos, se sugirió continuar modelando con redes neuronales la calidad del papel con datos del final de la parte húmeda de la máquina de papel.

### 6.2.4.3. Redes neuronales artificiales

El tercer intento de predecir la calidad del papel mediante modelado matemático se ha realizado mediante redes neuronales, con resultados muy prometedores. Para ello se han empleado, en un primer modelo, datos de Julio a Septiembre de 2004 para producción de papel *Prensa 45.0*. Este estudio preliminar servirá por tanto para la elección del método como sistema de modelado.

El índice de correlación “R<sup>2</sup>” y el error de predicción medio “ε” se han empleado como evaluadores de la calidad de la predicción de cada salida de los modelos. La tabla 6.20 recoge esta información del modelo preliminar. Los errores medios se han calculado mediante la ecuación 13, donde Max<sup>TR</sup> es el valor máximo de la salida evaluada en los datos de entrenamiento y Min<sup>TR</sup> su valor mínimo. De esta forma, la diferencia entre la predicción de las redes neuronales y los datos del proceso se transforma en porcentajes, comparables entre sí.

$$\varepsilon = \frac{|\text{Datos Pred} - \text{Datos PLab}|}{\text{Max}^{\text{TR}} - \text{Min}^{\text{TR}}} \cdot 100 \quad (13)$$

Tabla 6.20 – Coeficientes de correlación para los diferentes parámetros de calidad del papel en el modelado con redes neuronales.

	R <sup>2</sup>	Error medio (%)
Índice de formación	0.75	7.8
Rcia. Tracción	0.62	8.3
Elongación	0.62	7.8
Índice de desgarró	0.56	8.8
Brillo	0.19	12.3
Opacidad	0.19	11.2
Contenido Cenizas	0.44	9.7

Las correlaciones obtenidas han sido muy prometedoras. Por ejemplo el R<sup>2</sup> para la correlación entre el índice de formación medido y el predicho por el modelo ha sido 0.75 (ver figura 6.27), mucho mayor que el obtenido con la regresión múltiple (0.59). Por otro lado, como se esperaba, el brillo, la opacidad y el contenido de cenizas no se han podido predecir bien, basándose únicamente en parámetros

de la parte húmeda de la máquina de papel. Para estas predicciones se necesitarían también datos de la sección de producción de pasta.




Figura 6.27 – Resultados de la red “ANN-1” comparados con los datos medidos del índice de formación.

Los resultados mostrados en la tabla 6.20 son válidos para todo el periodo de tiempo analizado. Por tanto, la capacidad de generalización de las redes neuronales se ha considerado muy positiva para el modelado y sus posibilidades de mejora.

Con estos resultados preliminares, incluyendo una simulación con datos de Noviembre de 2004, las redes han mostrado ser una herramienta apropiada, por lo que se ha decidido continuar el estudio con esta técnica de modelado. Sin embargo, las capacidades de generalización en estos comienzos no se podían considerar óptimas debido a la técnica de minimización de errores en el algoritmo de retropropagación, cuyo criterio de parada se basaba en encontrar el mínimo error en validaciones con datos seleccionados al azar del mismo periodo que los datos de entrenamiento.

Con esta técnica se podía dar el caso de tener datos de validación muy parecidos a los de entrenamiento, con lo que podía incurrirse en un entrenamiento excesivo de la red que mermase su capacidad de generalización de comportamientos.

En este punto, se hizo necesario un estudio profundo incluyendo diferentes técnicas de validación, diferentes arquitecturas de red neuronal y diferente cantidad de datos de diferentes periodos de tiempo. Debido a la automatización del desarrollo de las redes neuronales, que se incluye como una de las tareas inherentes a la investigación, este proceso se consideró viable, y se ha procedido a su ejecución.

#### **6.2.5. Definición del esquema de modelado**

Una vez elegidas las redes neuronales para el modelado, se observó que existen numerosos factores que pueden influir sobre la robustez y precisión de los resultados. La arquitectura empleada en la red, los procesos elegidos de entrenamiento/validación y el intervalo de tiempo de datos empleados para el entrenamiento son algunos de esos factores.

Para optimizar todos los factores mediante una serie de etapas de modelado, ha de definirse un esquema apropiado, que es el objetivo de la presente tarea.

Tras el estudio preliminar mostrado en el capítulo anterior, se ha realizado un segundo estudio previo para acotar tanto los procedimientos de validación óptimos en el modelado como las arquitecturas y algoritmos de entrenamiento a emplear en los estudios completos.

Tras las etapas previas, el estudio completo servirá para optimizar el procedimiento de validación mediante el análisis de diferentes grupos de redes neuronales. El mismo proceso se aplicará para optimizar los intervalos de tiempo empleados en los datos de entrenamiento. El esquema general de modelado, con las tareas incluidas y los datos empleados en cada una de ellas, se resume en la figura 6.28.

Tanto los estudios preliminares como los más detallados siguen a su vez metodologías específicas basadas en la creación de numerosos modelos agrupados

según sus diferentes parámetros. En el apartado de la metodología se han definido los esquemas seguidos para la optimización de la arquitectura y el algoritmo de entrenamiento, la selección y agrupamiento de las mejores redes, y los procesos de entrenamiento, validación y simulación seguidos.

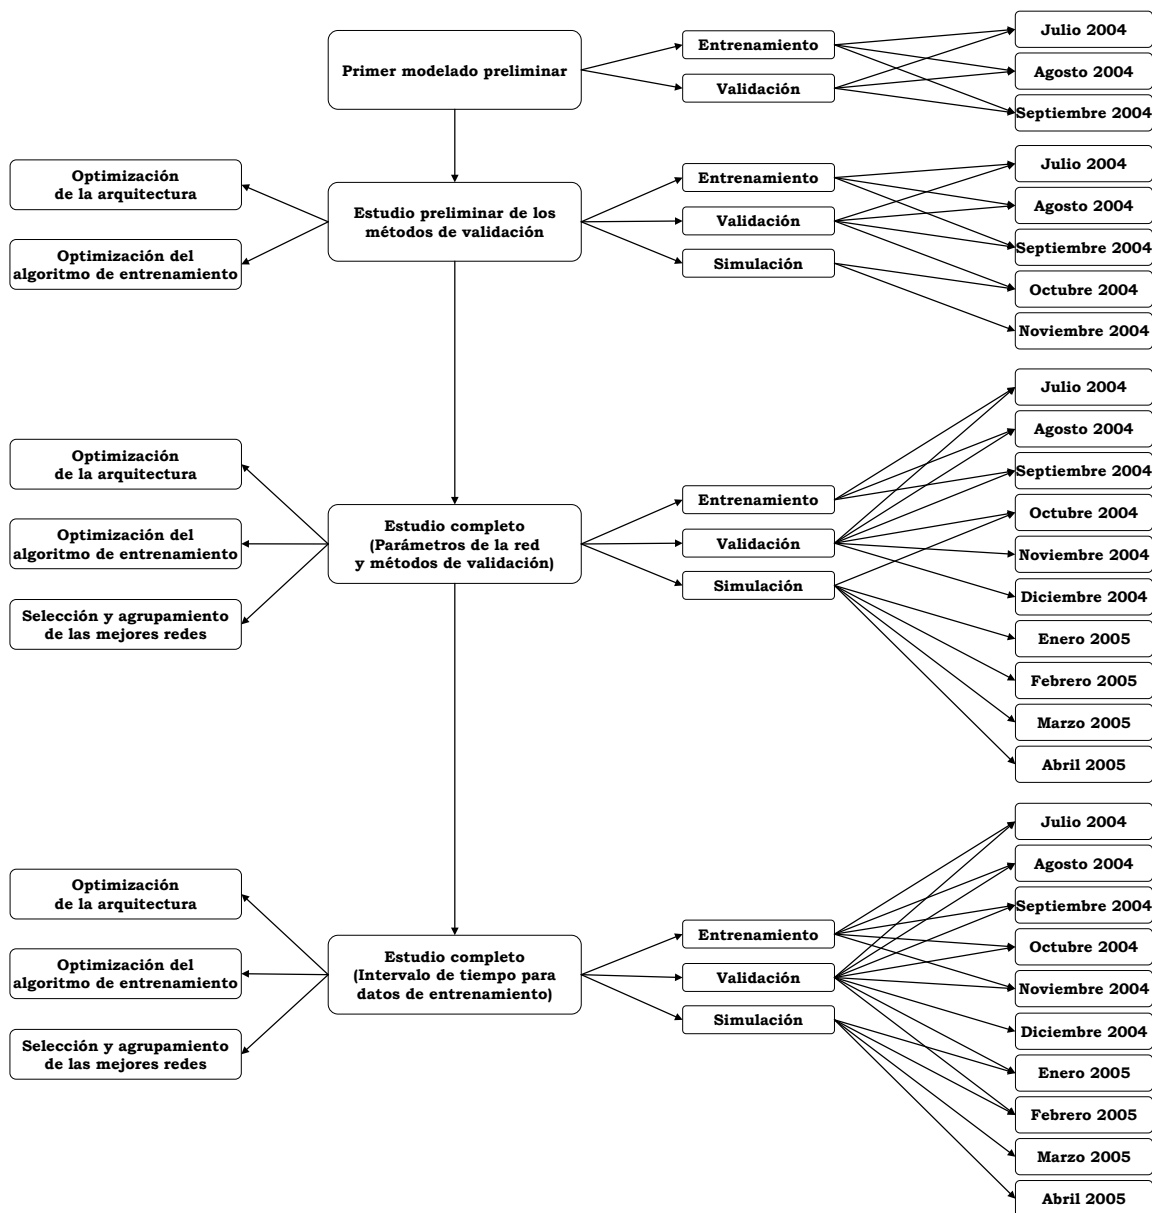


Figura 6.28 – Esquema de trabajo general para el modelado de la calidad del papel.

### **6.2.6. Modelado preliminar**

En todas las fases de modelado preliminar se ha empleado el algoritmo de gradiente descendente con momento y factor de aprendizaje variable debido al conocimiento previo de su empleo.

#### ***Primer estudio preliminar***

Anteriormente se describió el primer paso de modelado preliminar, muy simple, con el objetivo de justificar el empleo de las redes neuronales para predecir la calidad del papel.

Esta etapa se realizó para tener un estudio paralelo con redes de similares características que la desarrollada, pero variando las entradas al modelo. El objetivo es doble: por una parte se desea determinar el peso de las medidas del sensor FBRM en la capacidad de predicción de los modelos desarrollados y, por otra, comparar los resultados obtenidos con el sensor FBRM con medidas del medidor del índice de floculación *Kajaani* que está instalado en la caja de entrada. El objetivo, por tanto, es comparar la validez de ambos métodos de medida de la floculación para el modelado del final de la parte húmeda de la máquina de papel.

#### ***Red "ANN-1B", sin las medidas del sensor FBRM***

Esta red se ha realizado con el objetivo de determinar el peso de las medidas tomadas con el sensor FBRM en la calidad de las predicciones. En una primera fase, se han desarrollado cinco redes neuronales con los mismos parámetros que la red ANN-1, y la mejor de ellas se ha entrenado con algoritmo GDA hasta 60000 iteraciones, para evaluar los resultados.

El principal objetivo de esta red es el de la comparación de resultados, con lo que únicamente se muestra una tabla con el resumen de los mismos (Tabla 6.21). En la tabla 6.22 se analiza el peso de las medidas del sensor FBRM, mediante la evaluación de la diferencia en las correlaciones y errores entre las redes ANN-1 y ANN-1B.

Se observa una mejora media en el modelo de un 25% empleando el sensor FBRM, que proporciona una mayor robustez al validar los resultados. Por tanto, se puede concluir que el sensor FBRM es una herramienta válida y útil para la optimización de la calidad del papel a partir de medidas en línea del final de la parte húmeda de la máquina.

Tabla 6.21 – Errores medios e índices de correlación para cada salida de la red ANN-1B.

Carga de Rotura Longitudinal	Longitud de Rotura Longitudinal	Índice de Formación PLab	Opacidad PLab	Blancura ISO PLab	Contenido Cenizas QCS en Pope
<b>ERROR MEDIO %</b>					
8.68	9.07	5.95	8.69	11.2	2.17
<b>ÍNDICE DE CORRELACIÓN (R<sup>2</sup>)</b>					
0.52	0.51	0.60	0.16	0.26	0.10

Tabla 6.22 – ANN-1 y ANN-1B: Diferencias y peso de las medidas del sensor FBRM.

	Carga de Rotura Longitudinal	Longitud de Rotura Longitudinal	Índice de Formación PLab	Opacidad PLab	Blancura ISO PLab	Contenido Cenizas QCS en Pope
<b>ERROR MEDIO %</b>						
Diferencia	1.68	2.09	0.88	0.40	0.90	0.03
Peso medidas FBRM (mejora %)	19	23	15	4.6	8.0	1.4
<b>ÍNDICE DE CORRELACIÓN (R<sup>2</sup>)</b>						
Diferencia	0.16	0.19	0.11	0.06	0.12	0.03
Peso medidas FBRM (mejora %)	24	27	15	27	32	23
<b>Peso medio FBRM en R<sup>2</sup></b>	<b>25 %</b>					

Red "ANN-1C", sin las medidas del sensor FBRM y con el índice de floculación

Para comparar los dos métodos de medida de floculación (FBRM y Kajaani), se ha realizado el mismo análisis que entre las redes ANN-1 y ANN-1B, pero en este caso comparando las redes ANN-1 y ANN-1C. En la tabla 6.23 se resumen los resultados de la red ANN-1C (errores e índices de correlación), de la misma forma que se hizo con la red ANN-1B.

Tabla 6.23 – Errores medios e índices de correlación para cada salida de la red ANN-1C.

Carga de Rotura Longitudinal	Longitud de Rotura Longitudinal	Índice de Formación PLab	Opacidad PLab	Blancura ISO PLab	Contenido Cenizas QCS en Pope
<b>ERROR MEDIO %</b>					
8.48	8.57	5.44	8.52	11	2.11
<b>ÍNDICE DE CORRELACIÓN (R<sup>2</sup>)</b>					
0.55	0.56	0.67	0.19	0.28	0.09

En la tabla 6.24 se analiza la mejora del FBRM respecto al Kajaani como la diferencia de errores y correlaciones entre las redes ANN-1 y ANN-1C. Los porcentajes se refieren a los valores obtenidos con la red ANN-1C, para expresar la mejora.

Tabla 6.24 – Diferencia entre las redes ANN-1 y ANN-1C.  
Comparación medidas FBRM vs. Índice de Floculación.

	Carga de Rotura Longitudinal	Longitud de Rotura Longitudinal	Índice de Formación PLab	Opacidad PLab	Blancura ISO PLab	Contenido Cenizas QCS en Pope
<b>ERROR MEDIO %</b>						
Diferencia	1.48	1.59	0.37	0.23	0.70	-0.03
<b>ÍNDICE DE CORRELACIÓN (R<sup>2</sup>)</b>						
Diferencia	0.13	0.14	0.04	0.03	0.10	0.04
<b>Mejora media (%) de FBRM respecto a Kajaani en R<sup>2</sup></b>	<b>24</b>	<b>25</b>	<b>6.0</b>	<b>16*</b>	<b>36*</b>	<b>44*</b>

\*Datos obtenidos a partir de correlaciones bajas y de poca fiabilidad.

En el caso más favorable de predicción (el índice de formación), la medida del índice de floculación es especialmente adecuada, pero incluso en esta variable manejar las medidas del sensor FBRM proporciona una mejora del 6%. Esto implica dos conclusiones:

- Si se tuviese que elegir entre un solo método de medida para la floculación, este estudio demuestra que para este caso de modelado el sensor FBRM proporciona mejores resultados que el sensor *Kajaani*. Esto puede ser una información valiosa para pequeñas y medianas empresas que busquen resultados óptimos con un mínimo gasto en equipamiento.
- El sensor FBRM proporciona mejoras importantísimas en las predicciones de otros parámetros de calidad aparentemente no tan relacionados con la floculación, como pueden ser las propiedades mecánicas del papel. Esto puede ser debido a que el sensor FBRM no solo mide la floculación en sí, sino que proporciona una información muy completa acerca de la distribución de tamaños de partícula que, lógicamente, influirá en la resistencia del producto final.

### ***Segundo estudio preliminar***

En este segundo estudio se han desarrollado dos redes neuronales con datos de Julio a Septiembre de 2004 para papel *Prensa 42.5* con el fin de establecer una primera comparación acerca de diferentes métodos de validación. La única diferencia entre las dos redes es, por tanto, el conjunto de datos empleados en la validación al entrenar los modelos.

Los diferentes tipos de validación que se pueden tener en un estudio de estas características son:

- *Validación aleatoria*: En un periodo de tiempo dado, se reserva un porcentaje de los datos para validar el modelo creado con el resto de datos no reservados. Este método proporciona resultados óptimos si se presentan en el periodo estudiado cambios

numerosos y rápidos de las condiciones de operación, de tal forma que los datos de validación sean significativamente distintos a los de entrenamiento, aun siendo datos contiguos escogidos al azar.

- *Validación externa:* Los datos de entrenamiento pertenecen a un periodo de tiempo y los de validación a otro distinto. Este método se puede emplear cuando se desea una capacidad de predicción máxima en un periodo concreto no utilizable para el entrenamiento. Su empleo es poco frecuente. La validación cruzada se realiza con datos externos en cada paso, pero el resultado conjunto se puede asimilar matemáticamente a una validación mixta.
- *Validación mixta:* Es una mezcla de las dos anteriores, con parte de datos del periodo de entrenamiento y parte de fuera. Resulta adecuada en la mayoría de los casos, debido a que proporciona resultados óptimos en sistemas con variación moderada en el tiempo, cuando se desea tener predicciones que reproduzcan fielmente no solo el intervalo modelado, sino cualquier periodo.

A continuación se describen los datos empleados en las dos redes desarrolladas para este estudio:

- En la red ANN-1 se han empleado 8593 datos de fábrica para entrenamiento, y otros 2858 para validación aleatoria (se ha reservado para validación un 25% de los datos). Esta red fue la desarrollada en el primer estudio con redes, teniendo en cuenta estos estudios posteriores.
- En la red ANN-2 se han empleado los mismos datos de entrenamiento (los mismos 8593 datos) que en la red ANN-1, y en este caso se han añadido a los datos de validación de la red ANN-1 (2858 datos de Julio a Septiembre de 2004) otros 1209 datos de validación de Octubre de 2004.

### **ANN-1**

La figura 6.27 es un ejemplo de la comparación de los datos de laboratorio y los predichos para el periodo de Julio a Septiembre de 2004. Al emplear los datos de validación del mismo periodo que los de entrenamiento, siendo datos muy parecidos entre sí, lógicamente las predicciones en ese mismo periodo fueron muy

buenas y difícilmente superables, con lo que el error de validación ha resultado ser el mínimo de todos los modelos desarrollados.

Todos los errores de validación y simulación han sido calculados con la ecuación 13, anteriormente explicada.

Los resultados de la simulación de los periodos de Octubre y Noviembre de 2004 con esta red neuronal se muestran en la figura 6.29. Esta red no se ha validado con datos de los meses de Octubre o Noviembre de 2004, que pudieran ser similares o aportar información, con lo que los errores de predicción dependen de si los datos de entrenamiento han tenido en cuenta las condiciones de operación en estos meses. Como se observa, los errores de predicción de Octubre y Noviembre son muy diferentes, debido a esta circunstancia.




Figura 6.29 – Errores medios para los diferentes parámetros de calidad obtenidos por modelado con redes neuronales y validación aleatoria (ANN-1) o validación mixta (ANN-2).

**ANN-2**

En esta red se ha empleado la validación mixta, incluyendo una porción de datos de Octubre de 2004 en la validación y el resto de datos de Octubre y datos de Noviembre de 2004 en la simulación posterior. Los resultados se recogen también en la figura 6.29.

En la validación, la red ANN-1 proporciona lógicamente mejores resultados que la red ANN-2. Este hecho se debe al proceso de entrenamiento en sí, con datos de Julio a Septiembre de 2004 y un criterio de parada basado en la validación con datos del mismo periodo de tiempo que los de entrenamiento, que son bastante parecidos. El problema con el empleo de esta red surge al simular otros periodos de tiempo, donde no se simulan correctamente todas las condiciones de operación.

Es aquí donde la red ANN-2 (similar a la ANN-1 pero con más datos de validación, procedentes de Octubre de 2004) muestra una capacidad de generalización mucho mayor. La tabla 6.25 recoge el error medio porcentual de cada red ponderando las distintas salidas de los modelos.

Tabla 6.25 – Errores medios de las redes neuronales desarrolladas en el segundo estudio preliminar.

	Validación	Simulación	
		Octubre 2004	Noviembre 2004
<b>ANN-1</b>	8.2	14.7	15.5
<b>ANN-2</b>	9.3	11.5	11.3

En la validación, la red ANN-1 muestra un error 13% menor pero, al simular, los errores son un 25% menores al trabajar con la red ANN-2, con validación mixta. Por tanto, este tipo de validación es la indicada para obtener modelos de máxima robustez.

Este hecho también se denota al comparar los errores de validación y simulación en cada modelo. En la red ANN-2, ambos valores se encuentran más próximos entre sí, lo que indica que al aplicar el modelo en diferentes periodos de tiempo se tienen resultados similares y, por tanto, robustos.

Por las conclusiones mencionadas de esta fase, resumidas en el apartado de conclusiones, se ha considerado necesario elaborar un estudio en profundidad, que compare diferentes posibilidades de validación.

### **6.2.7. Estudio completo**

#### ***Optimización de la arquitectura y del algoritmo de entrenamiento***

##### *Gradiente Descendente vs. Levenberg-Marquardt*

Como ya se ha indicado en el apartado de herramientas matemáticas, estudios previos realizados en este mismo Grupo de Investigación han mostrado que las redes neuronales con algoritmos de retropropagación con gradiente descendente (GDA), generalmente con valores elevados del momento (en torno a 0.9), y factor de aprendizaje variable, proporcionan resultados robustos.

Sin embargo, el algoritmo GDA presenta una gran desventaja en los planes a largo plazo. Como uno de los objetivos es crear un modelo en línea que se actualice o mejore periódicamente, el tiempo de computación adquiere gran importancia debido al tiempo necesario para las actualizaciones. Como alternativa al GDA, se han desarrollado redes neuronales con el algoritmo de Levenberg-Marquardt (LMA), una capa oculta y número de neuronas a optimizar en la capa oculta. Los resultados han sido similares con ambos algoritmos, como se verá a continuación, pero las redes creadas con el algoritmo LMA han sido entrenadas en un tiempo mucho más reducido.

##### *Arquitectura óptima*

En las figuras 6.30 a 6.33 se muestra que existe un intervalo óptimo de neuronas ocultas que le dan a la red neuronal la capacidad de aprender los comportamientos complejos sin un aprendizaje excesivo. Estas figuras se muestran en inglés, debido al programa empleado en origen. Posteriormente se comentarán ejemplos de las posibles interpretaciones de este tipo de gráficas y se verá, por tanto, su gran utilidad en el modelado.

En los ejes de abscisas se tiene el término “Epochs” que significa épocas. En la nomenclatura habitual se habla de iteraciones, pero conviene explicar que en la programación se entiende por iteración el proceso de cambio de pesos realizado

con un solo dato presentado a la red. Cuando se termina de presentar todos los datos disponibles, se habla de que ha concluido una época. No obstante se hablará habitualmente de iteraciones, refiriéndose a las épocas.

En el eje de ordenadas se muestran los errores cuadráticos medios (MSE), en azul el de entrenamiento (TrainMSE) y en rojo el de validación (ValidMSE). En la parte superior de las figuras se muestran, en este orden, el momento, número de neuronas en la capa oculta y número de identificación de la red neuronal. En las redes creadas con algoritmo de LMA, al no emplear momento, este se muestra como "0".

Las arquitecturas óptimas han sido seleccionadas con el análisis de los resultados de más de un centenar de modelos. Se ha observado también que el algoritmo LMA proporcionó resultados similares con menor requerimiento de tiempo de computación y con un intervalo óptimo de neuronas en la capa oculta entre 3 y 7.

En la figura 6.30 se observa que, con un número excesivo de neuronas en la capa oculta, el aprendizaje se vuelve difícil y requiere gran cantidad de tiempo.




Figura 6.30 – Errores cuadráticos medios de entrenamiento y validación (MSE) para una de las redes desarrolladas con algoritmo GDA.

En la figura 6.31 se ve, en cambio, que con un menor número de neuronas en la capa oculta, se obtienen menores errores de validación pese a unos errores de entrenamiento ligeramente más elevados. Se observa claramente el fenómeno de aprendizaje excesivo tras el punto óptimo (aproximadamente a 2500 iteraciones), ya que el error de validación tiende de nuevo a ser mayor tras éste.

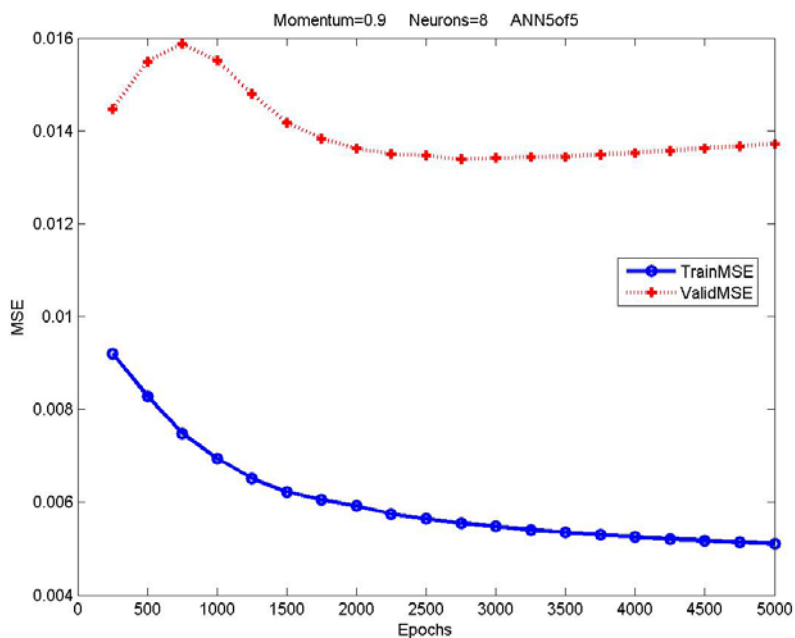


Figura 6.31 – Errores cuadráticos medios de entrenamiento y validación (MSE) para una de las redes desarrolladas con algoritmo GDA.

En el caso de la figura 6.32, se observa de nuevo el aprendizaje excesivo, pero tras únicamente 15 iteraciones.




Figura 6.32 – Errores cuadráticos medios de entrenamiento y validación (MSE) para una de las redes desarrolladas con algoritmo LMA.

En la figura 6.33, tiene lugar muy pronto el aprendizaje excesivo, tras solo seis iteraciones. Se observa también que el error de validación es superior a los casos con menor número de neuronas en la capa oculta.

### *Distribución en el tiempo de los datos de validación con respecto a los de entrenamiento*

Al seleccionarse el algoritmo LMA, las redes neuronales han sido entrenadas hasta con 40 iteraciones, cantidad considerada suficiente en los estudios preliminares. La distribución en el tiempo de los datos de validación se muestran en la tabla 6.26. Para la construcción de cada grupo de redes, se han desarrollado cinco redes neuronales para cada número de neuronas ocultas, y del total de 25 redes, han sido analizadas en detalle las 5 con mejores resultados, para estudiar sus errores tanto de validación como de simulación (Ver tabla 6.27)




Figura 6.33 – Errores cuadráticos medios de entrenamiento y validación (MSE) para una de las redes desarrolladas con algoritmo LMA.

Tabla 6.26 – Datos empleados en cada grupo desarrollado de redes neuronales.

	GRUPOS DESARROLLADOS								
	ANN-1	ANN-2	ANN-3	ANN-4	ANN-5	ANN-6	ANN-0	ANN-2B	ANN-2C
Datos del periodo de entrenamiento (07-09/2004)	2907	2907	2907	2035	1163	581	2907	2907	2907
Datos de periodos externos	581	1163	2035	2907	2907	2907	0	1163	1163
% de datos en periodos externos	17	29	41	59	71	83	0	29	29

Tabla 6.27 – Error cuadrático medio para cada una de las redes óptimas seleccionadas para el análisis. Cálculo por grupos de la media del error de simulación cometido.

Simulación 1							Media
ANN-1	0.0089	0.0071	0.0050	0.0064	0.0076		0.0070
ANN-2*	0.0090	0.0055	0.0062	0.0077	0.0077		0.0072
ANN-3	0.0050	0.0058	0.0059	0.0062	0.0076		0.0061
ANN-4	0.0055	0.0051	0.0046	0.0137	0.0054		0.0069
ANN-5	0.0126	0.0067	0.0055	0.0049	0.0068		0.0073
ANN-6	0.0050	0.0062	0.0093	0.0060	0.0107		0.0074
ANN-0			0.0068	0.0118	0.0105		0.0097
ANN-2B*	0.0109	0.0053	0.0089	0.0087	0.0069		0.0081
ANN-2C*	0.0126	0.0129	0.0117	0.0123	0.0106		0.0120
Simulación 2							Media
ANN-1	0.0456	0.0357	0.0357	0.0348	0.0334		0.0370
ANN-2*	0.0421	0.0370	0.0476	0.0386	0.0351		0.0401
ANN-3	0.0357	0.0335	0.0361	0.0337			0.0348
ANN-4	0.0354	0.0343	0.0356	0.0411	0.0416		0.0376
ANN-5	0.0407	0.0382	0.0353	0.0533	0.0484		0.0432
ANN-6	0.0372	0.0341	0.0344	0.0359	0.0389		0.0361
ANN-0			0.0755	0.0371	0.0397		0.0508
ANN-2B*	0.0417	0.0464	0.0491	0.0430	0.0469		0.0454
ANN-2C*	0.0610	0.0574	0.0589	0.0592	0.0582		0.0589
Validación							Media
ANN-1	0.0068	0.0069	0.0069	0.0069	0.0070		0.0069
ANN-2*	0.0077	0.0085	0.0085	0.0087	0.0089		0.0085
ANN-3	0.0089	0.0092	0.0092	0.0093	0.0096		0.0092
ANN-4	0.0101	0.0104	0.0105	0.0111	0.0112		0.0107
ANN-5	0.0108	0.0108	0.0111	0.0120	0.0125		0.0114
ANN-6	0.0097	0.0115	0.0117	0.0120	0.0124		0.0115
ANN-0			0.0045	0.0046	0.0046		0.0046
ANN-2B*	0.0079	0.0082	0.0086	0.0086	0.0087		0.0084
ANN-2C*	0.0077	0.0078	0.0079	0.0080	0.0081		0.0079

\*Empleadas para determinar la cantidad óptima de tiempo a emplear en el entrenamiento.

La figura 6.34 muestra gráficamente todos estos errores para todos los grupos de redes neuronales. La simulación 1 se refiere a datos externos de los 15 días posteriores al periodo de entrenamiento, mientras que la simulación 2 se refiere a datos externos tomados tres meses después del periodo de entrenamiento en los grupos ANN 0 a 6. Para el grupo ANN-2B, la simulación 2 se refiere a datos tomados dos meses y medio después del periodo de entrenamiento, y en el caso del grupo ANN-2C, 2 meses después.




Figura 6.34 – Errores de validación y simulación para todos los grupos de redes neuronales creados. El número encima de cada grupo de barras representa el porcentaje de datos externos para validación.

Estas diferencias se han debido a la limitación en la cantidad de tiempo de los datos disponibles. Lógicamente, los errores cometidos en la simulación 2, más lejana en el tiempo, son mayores.

Se puede observar que los grupos ANN-3 y ANN-4 tienen un MSE similar entre ellos, y esto ocurre para ambas simulaciones, donde presentan los valores más reducidos del MSE. Por tanto, una colección de datos de validación con un porcentaje de datos externos de entre un 40% y un 60%, resulta óptimo para conseguir la máxima robustez.

De la misma manera, el grupo ANN-0, desarrollado únicamente con datos de validación procedentes del periodo de entrenamiento, como lo fuera la red ANN-1 en los estudios preliminares, proporciona el menor error de validación, mientras que en las simulaciones los errores son significativamente mayores debido a la falta de capacidad de generalización respecto a los grupos de redes 1 á 6.

Este resultado responde al mismo comportamiento ya visto en el segundo estudio preliminar y, en este caso, se han comprobado los errores de validación según el porcentaje de datos de validación externos. El comportamiento observado es el esperado, de un aumento gradual del error según aumenta el porcentaje de

datos externos. En la figura 6.34 se ve tanto el citado aumento como los porcentajes estudiados, encima de cada grupo de barras.

### ***Intervalo de tiempo considerado para los datos de entrenamiento***

Cuando se construyen modelos en línea, que pueden ser actualizados con el tiempo, resulta crucial el intervalo de tiempo empleado para la selección de los datos de entrenamiento, debido a los tiempos de computación, la robustez del modelo, y el comportamiento dinámico del mismo con el tiempo. Por tanto, ha de llevarse a cabo de antemano una selección del tamaño óptimo para el citado intervalo, antes de la construcción de un modelo en línea.

En este estudio se han incluido tres grupos de redes neuronales:

- ANN-2, con datos de entrenamiento de Julio a Septiembre de 2004.
- ANN-2B, con datos de entrenamiento de Julio a Octubre de 2004.
- ANN-2C, con datos de entrenamiento de Julio a Noviembre de 2004.

Los tres grupos presentan la misma proporción de datos externos en la validación. En la tabla 6.27 y la figura 6.34 se resumen todos los errores de validación y simulación.

Los errores de validación son similares en los tres grupos, debido a la similitud en la proporción de datos externos de validación. Sin embargo, se ha observado un aumento de los errores de simulación según el intervalo de datos de entrenamiento se hace mayor. La conclusión para este caso, en principio, sería clara, y diría que con tres meses de datos es suficiente, con lo que debería optimizarse este tiempo con intervalos menores. Pero de acuerdo con los resultados obtenidos del empleo de regresiones múltiples, la robustez se puede ver afectada al emplear intervalos de tiempo menores. Debido al reducido intervalo de tiempo con medidas disponibles, este estudio ha presentado resultados basados en simulaciones de periodos ligeramente diferentes. Una vez que se disponga de un intervalo mayor de tiempo con datos válidos para un estudio de esta naturaleza, se podría realizar un estudio más exhaustivo para obtener las conclusiones oportunas.

### ***Robustez de los modelos desarrollados***

Los errores de simulación obtenidos para cada grupo de redes en las simulaciones 1 y 2, vistos en la tabla 6.27, proporcionan una comparación de su robustez. La mejor red neuronal obtenida en términos de su error de validación, que es la forma de seleccionar previamente los modelos, ha sido analizada como ejemplo de un modelo que muestra una gran robustez en las dos simulaciones realizadas.

En la figura 6.35 se muestra un ejemplo de la simulación 1 para el índice de formación. Ha de destacarse que la variabilidad de esta medida en el periodo de la simulación 1 es bastante reducida, con lo que las diferencias que se ven en la figura son significativamente pequeñas (Ver tabla 6.28). Los errores se calculan de nuevo con el mismo método que anteriormente.




Figura 6.35 – Simulación 1 del índice de formación con la mejor red neuronal, del grupo ANN-3.

Tabla 6.28 – Errores de la simulación 1 para cada variable de salida con la mejor red neuronal, del grupo ANN-3.

	Carga de rotura longitudinal	Longitud de rotura longitudinal	Índice de formación
Error medio ( $\epsilon$ ) (%)	9.0	7.6	4.4

Cuando se simula esta misma red con datos obtenidos tres meses después del intervalo de entrenamiento, los errores lógicamente aumentan considerablemente, pero continúan siendo aceptables, según se observa en la tabla 6.29.

Tabla 6.29 – Errores de la simulación 2 para cada variable de salida con la mejor red neuronal, del grupo ANN-3.

	Carga de rotura longitudinal	Longitud de rotura longitudinal	Índice de formación
Error medio ( $\epsilon$ ) (%)	13	17	9

Cuando se representan todas las segundas simulaciones, es alentador el hecho de comprobar que, tres meses después de desarrollar el modelo, éste continuará prediciendo la mayor parte de las fluctuaciones, como se puede observar en la figura 6.36. Lógicamente existen periodos con condiciones de operación para las que el modelo no ha sido entrenado, y este es el motivo de la necesidad de crear modelos en línea, que se actualicen con el tiempo.




Figura 6.36 – Simulación 2 de la carga de rotura longitudinal con la mejor red neuronal, del grupo ANN-3.

Como conclusión se puede decir que se han construido modelos de gran robustez basados en medidas del final de la parte húmeda de la máquina de papel, con errores de predicción de un 10-15%. La robustez se ha comprobado con dos simulaciones en distintos periodos de tiempo, incluyendo datos hasta 6 meses posteriores a los empleados en el entrenamiento del modelo.

### 6.2.8. Segunda selección de variables

Una vez seleccionados los modelos óptimos, ha de calcularse la influencia de cada entrada sobre cada salida y así, de acuerdo con las influencias calculadas y la experiencia del personal de fábrica, se puede realizar una selección de un número muy reducido de entradas (con un máximo de 2 ó 3) a utilizar en el modelado de optimización.

En esta fase se deben emplear únicamente los modelos provenientes de estudios completos, ya que se busca la máxima robustez. Se han calculado los impactos de cada entrada sobre cada salida para los modelos de predicción de la calidad del papel, calculando los impactos medios a partir de todas las redes neuronales seleccionadas de cada grupo, con el fin de evitar valores puntuales obtenidos con una sola red o un solo grupo, y que estos sean generales y fiables. La tabla 6.30 muestra los impactos calculados según las reglas descritas en la bibliografía (Chitra, 1993). Los impactos se han relativizado respecto al más fuerte de ellos, al que se le asigna el valor 100.

Tabla 6.30 - Impactos relativos de las entradas sobre cada salida de los modelos (salidas en cabeceras de fondo gris oscuro). Todos los valores restantes son menores de 30. Los impactos positivos se señalan con fondo gris claro, y los negativos con fondo gris oscuro.

Plab Carga de Rotura Longitudinal		Plab Longitud de Rotura Longitudinal	
cps (34-1000 $\mu\text{m}$ )	100	Mediana, No Wt	100
Mediana, No Wt	95	cps (34-1000 $\mu\text{m}$ )	99
PM61 Cons. Caja de Entrada DCS	68	PM61 Cont. Cenizas caja de entrada	62
PM61 Cont. Cenizas caja de entrada	57	PM61 Cons. Caja de Entrada DCS	58
Índice de Formación		Impacto Total	
cps (34-1000 $\mu\text{m}$ )	100	cps (34-1000 $\mu\text{m}$ )	100
Mediana, No Wt	75	Mediana, No Wt	93
cps (1-5 $\mu\text{m}$ )	55	PM61 Cont. Cenizas caja de entrada	53
Caudal DIP2 a mezclador	40	PM61 Cons. Caja de Entrada DCS	50

Este es el punto de partida para decidir qué variables deben ser empleadas en el modelo de “*Optimización*”. Se ve que, en principio, las medidas tomadas con el sensor FBRM son las más influyentes. Por consiguiente, la toma de medidas en continuo con este sensor ayudaría en gran medida a tener un modelo en línea robusto para la optimización de la calidad del papel.

Debido a la naturaleza del proceso de fabricación de papel, no siempre se puede actuar sobre las variables seleccionadas como las más influyentes. Por ejemplo, resulta casi imposible actuar sobre la consistencia de la caja de entrada o sobre los caudales, con lo que una vía mucho más sencilla de optimización de la calidad del papel sería a través del control de la físico-química del final de la parte húmeda para situarse en intervalos óptimos de las medidas del sensor FBRM, es decir, del tamaño de los agregados formados mediante el control de la dosificación de los aditivos del sistema de retención.

#### **6.2.9. Modelado “de optimización”**

Una vez seleccionado un número reducido de variables de entrada (en este caso las dos medidas más influyentes, tomadas con el sensor FBRM), se inicia un esquema similar de trabajo al del estudio completo, pero esta vez con los modelos reducidos “de optimización”, a los que se les ha dado este nombre debido a su finalidad, que es proporcionar, a partir de sus resultados, recomendaciones de intervalos para cada entrada.

La verdadera utilidad se muestra cuando se tiene la posibilidad de controlar los valores de las entradas en fábrica, de forma que se cumplan las recomendaciones obtenidas, lo cual supondrá, con un gran intervalo de confianza, una mejora de la calidad media del producto, así como una estabilización de la misma con el tiempo.

Estos modelos han de crearse a demanda de la fábrica, y persiguen objetivos muy concretos como el control de secciones como la parte húmeda de la máquina a partir de medidas muy específicas.

### **6.2.10. Actualización/mejora de los modelos**

Se han planeado distintas alternativas para pasar del modelado estático (ampliamente conocido con el término anglosajón “off-line”), a un modelado que constituya un sistema en línea y automático de ayuda a la toma de decisiones. Este sistema se basará en diferentes modelos que se pueden emplear como sensores virtuales de la calidad.

En un trabajo realizado en colaboración con la Universidad Tecnológica de Tampere (TUT-Finlandia), se han barajado principalmente dos opciones:

- Crear un sistema de actualización de parámetros internos de las redes neuronales con el tiempo.
- Construir un sistema de conmutación que permita tanto la selección del mejor modelo según las condiciones de operación (se crearían modelos diferentes en paralelo), como la actualización de un modelo genérico, que se emplearía para generalizar datos extraños o de condiciones de operación novedosas para el sistema.

El primer sistema presenta, en principio, la dificultad de que incluso una red neuronal sencilla, de una sola capa oculta y solo tres neuronas, tres entradas y una salida, por ejemplo, únicamente con los pesos internos suma ya doce parámetros, con lo que la aplicación de sistemas de validación dinámica con este número de parámetros haría compleja la tarea, a la vez que requeriría gran cantidad de tiempo.

En cambio, parece que la segunda opción puede resultar más adecuada e incluso proporcionar resultados más exactos, minimizando el riesgo de una toma de decisiones errónea debido a fallos en las predicciones. No obstante, la decisión final requerirá de mayor experiencia en este campo, y será tomada en una fase más avanzada del trabajo.

En la segunda opción, el sistema de conmutación puede construirse de varias formas. La validación dinámica se está empleando actualmente en la Universidad Tecnológica de Tampere (TUT). Para mejorar el conocimiento de la misma se ha intercambiado información entre investigadores de la Universidad Complutense de Madrid y de la TUT en un trabajo recogido en la bibliografía (Konkarikoski K. y Alonso A., 2008).

### Concepto de Validación Dinámica

En esta fase, se ha desarrollado un sistema preliminar híbrido combinando redes neuronales y validación dinámica. En la figura 6.37 se muestra el concepto de la validación dinámica aplicada a una salida de una red neuronal.

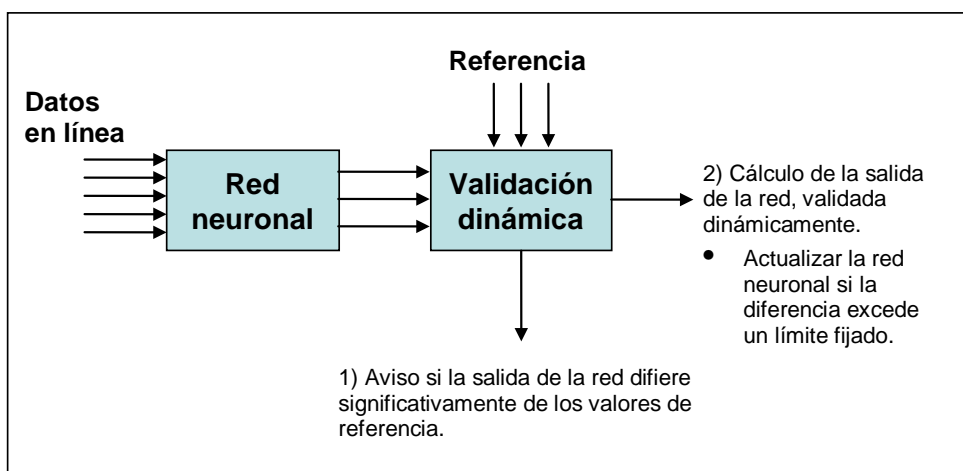


Figura 6.37 – Concepto de validación dinámica de una salida de una red neuronal.

Las salidas de la red neuronal y las correspondientes medidas de referencia (datos medidos en fábrica) son las entradas del bloque de validación dinámica. En este bloque, se establece un modelo lineal simple entre las salidas de la red y las medidas de referencia. Este modelado se puede realizar mediante un modelo para cada salida (conocidos por el anglosajón “SISO: Single Input / Single Output”), o modelos combinados con todas las variables (conocidos como “MIMO: Multiple Input / Multiple Output”).

El modelo más simple (SISO) tiene la conocida forma “ $y = a \cdot x + b$ ”, donde “ $x$ ” es la salida de la red neuronal e “ $y$ ” su correspondiente medida de referencia. En un caso ideal, con una salida de la red idéntica a la referencia, el parámetro “ $a$ ” es igual a 1 y “ $b$ ” es igual a 0.

Una vez se ha llegado a este punto, se presentan dos opciones:

1. Observar el modelo dinámicamente y generar señales de aviso según se deba entrenar la red empleada o utilizar otra nueva red, cuando se vean diferencias significativas entre el modelo supervisado y el original.
2. Actualizar dinámicamente los parámetros del modelo lineal. De esta forma la red neuronal se comportaría como la parte estática del modelo, mientras que el modelo lineal, dinámico, se conecta en serie a la red neuronal. En este caso se acumula el error de la red neuronal con el del modelo dinámico.

### *Caso práctico*

La figura 6.38 muestra un ejemplo de caso práctico de validación dinámica de la salida de un sistema de redes neuronales en paralelo. Se entrenan varias redes con las que se crea un sensor virtual a partir de datos en línea. Aquí se ubicarían los modelos ya desarrollados de predicción, que podrían ser tanto el modelo completo como el reducido, debido a sus diferentes utilidades.

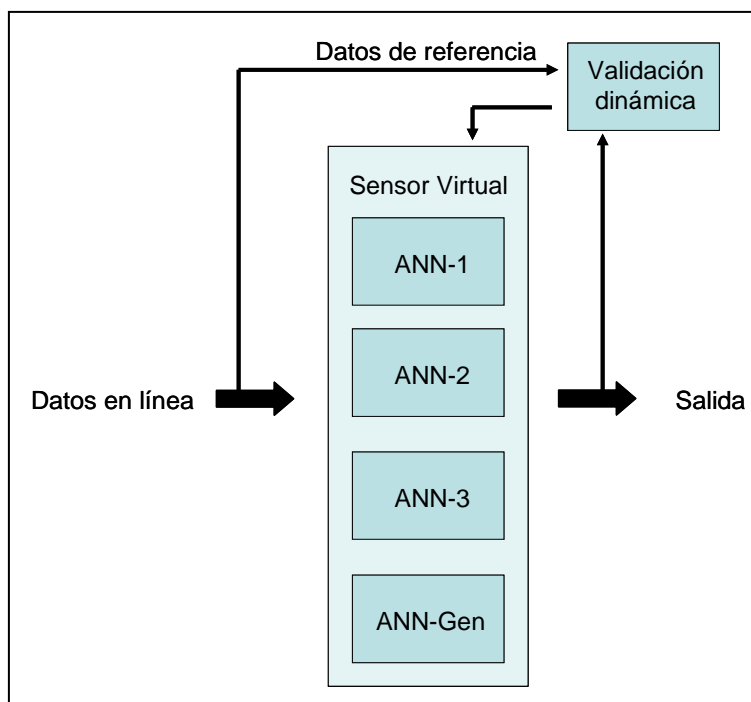


Figura 6.38 – Caso práctico de validación dinámica de la salida de una red neuronal.

Con las redes ya entrenadas, se utiliza la que mejor predice las condiciones de operación en el momento de la puesta en marcha (podría emplearse cualquiera, ya que el modelo cambiaría a la correcta en la primera fase de validación dinámica). La salida del modelo empleado se compara con los datos de referencia, una vez disponibles, y si la diferencia es significativa se lanza una señal de aviso y se procede a la actualización de las redes neuronales.

Aquí el bloque de validación dinámica actúa como estimador de las condiciones de operación. Se procede a un cálculo del error con las redes disponibles en paralelo y se elige la que predice con mayor exactitud la situación actual. Si ninguna de las redes proporciona una buena predicción se recurre a una red genérica construida con todo tipo de datos y gran capacidad de generalización. Si esta red tampoco funciona, se actualiza la misma. Una alternativa a esta actualización es el conocimiento de cambios importantes en el sistema, que podrían desembocar en el entrenamiento de nuevas redes que serían incorporadas al sistema dinámico.

#### **6.2.11. Automatización de todas las tareas anteriores**

Todas las tareas llevadas a cabo requieren de la creación de archivos de secuencia empleando para ello el código de programación de Matlab, que permite que el esquema de modelado se realice automáticamente.

Los programas, que comenzaron con el desarrollo de redes neuronales en la industria del fibrocemento, se han ido mejorando hasta incluir actualmente interfaces de usuario, más de 2000 líneas de código divididas, en este momento, en 45 archivos, entre los archivos de llamada de procedimiento y distintas subrutinas, creadas por completo en la presente tesis doctoral, y de gran utilidad para trabajos que ahonden en las presentes investigaciones.

En el caso de la industria del papel, se han realizado también pequeños programas de conversión y filtrado de datos en la fase de procesado previo de los datos. La creación de hojas de Excel, incluyendo secuencias de programación e importación desde el sistema WinMOPS, ha ayudado también en gran medida.

Existe un proceso continuo de mejora, eliminación de fallos de programación, resolución de excepciones y adición de nuevas funciones, lo que supondrá una gran ventaja cuando se proceda a la implementación de este trabajo en los sistemas ya instalados en fábrica.

Otra gran ventaja de esta tarea reside en que, pese a aumentar el tiempo del primer análisis, reduce considerablemente análisis futuros, con un ahorro de más de la mitad del tiempo necesario para el modelado.

#### **6.2.12. Tareas relacionadas (entrenamiento de operarios, implementación del modelo)**

Todo el esquema de modelado visto anteriormente se encuentra integrado dentro de la creación de un sistema inteligente de ayuda a la toma de decisiones en fábrica. Como ya se ha comentado, también se trabaja en la elaboración de interfaces de usuario de fácil empleo, que permitan un fácil desarrollo y aceptación de la herramienta que se ha comenzado a construir.

Dentro de las tareas de programación, la última fase se centrará en la implementación de la estructura del sistema creado dentro de la fábrica de papel. Uno de los principales objetivos será el empleo de las herramientas desarrolladas para entrenar a los operarios en escenarios virtuales.

## 7. DESARROLLO DE PROGRAMAS

Es conveniente destacar que estos programas, que representan la metodología de trabajo, se pueden considerar también un resultado de la investigación, por lo que se recogen todos ellos en el anexo VII.

En dicho anexo se comenta la función de cada uno de los programas. Desde subrutinas que crean redes neuronales hasta programas que las entrenan, simulan y representan las respuestas, estos programas son variados, y el código, en ningún caso, se encuentra exento de mejoras y/o modificaciones. Dichas mejoras supondrían la compilación de estos archivos en librerías DLL o autoejecutables, lo cual, unido a mejoras en la interfaz de usuario, podría dar como resultado un software propio de empleo de redes neuronales.

## 8. CONCLUSIONES

### 8.1. MEJORAS EN LA OPTIMIZACIÓN DE LA FABRICACIÓN DE FIBROCEMENTO

Las investigaciones desarrolladas en este trabajo han permitido obtener las siguientes conclusiones:

- Se pueden establecer, en tiempo real y a escala industrial, buenas correlaciones entre las propiedades mecánicas y los parámetros característicos de los procesos de floculación. El FBRM se puede considerar un buen sensor para la predicción inmediata.
- Con las distintas redes neuronales creadas para predecir diferentes propiedades se han alcanzado resultados similares, indicando una gran robustez de las predicciones. Las mejores predicciones son para el  $F_s$  a las 48 horas y a los 7 días.
- Las recomendaciones establecidas permitirán a la fábrica optimizar el proceso, ya que las entradas seleccionadas para las redes son fácilmente ajustables en fábrica, mediante cambios en la adición de floculante.
- El número total de cuentas y el comprendido en el intervalo 10-32  $\mu\text{m}$  son los estadísticos más significativos del FBRM para la predicción de las propiedades finales del fibrocemento.
- Las redes E y F distinguen entre variables predecibles e impredecibles. Los espesores, fijados por operario, presentan los peores índices de correlación en ambas redes (0.36 para el espesor a las 48 horas y 0.40 para el espesor a los 7 días), mientras los índices de clase y el momento flector presentan buenas predicciones, con coeficientes de correlación de 0.80 para el índice de clase a 48 horas y 7 días, de 0.74 para el momento flector a 7 días, y de 0.81 para la densidad a los 7 días, lo que supone un gran avance, al no tener que esperar 7 días para tener los ensayos más fiables de calidad, y poder establecer un control activo de calidad en tiempo real.
- Las redes neuronales han demostrado gran capacidad de predicción, incluso para diferentes perfiles de placas, como es el caso de la RED-F, con coeficientes de correlación de 0.82 y 0.88 para el índice de clase a 48 horas y 7 días respectivamente, de 0.68 para el momento flector a 7 días, y de 0.75 para la densidad a los 7 días.
- Los errores de predicción son similares para las redes creadas específicamente para predecir una propiedad (redes B, C y D), que en la

RED-F, creada para predecir todas las propiedades a la vez. Incluso con esta RED-F se obtiene el mejor resultado, para el índice de clase a los 7 días.

- La RED-F presenta prácticamente idénticas conclusiones que las obtenidas con las redes B, C y D, lo cual, unido a la mejora de las predicciones en los  $F_s$ , hace que su empleo resulte ventajoso al tratarse de una única red, obtenida con un solo proceso de optimización, con el consiguiente ahorro de tiempo.

## 8.2. MEJORAS EN LA OPTIMIZACIÓN DE LA FABRICACIÓN DE PAPEL

Tras los estudios preliminares, se han obtenido las siguientes conclusiones:

- La validación es una etapa crucial del modelado. Al emplearla como criterio de parada en los algoritmos de entrenamiento, la calidad de las predicciones depende en gran medida de la metodología empleada para la validación.
- La validación mixta proporciona en este caso resultados más robustos que la validación aleatoria (se ha experimentado una reducción del error de simulación de un 27% en datos de Noviembre de 2004 al cambiar el tipo de validación). Por tanto será necesario el probar distintas posibilidades de validación mixta para mejorar la robustez de los resultados.
- El índice de formación es la variable para la cual se han obtenido mejores predicciones.

De los estudios detallados se concluye:

- Los datos disponibles en el sistema WinMOPS han sido filtrados con éxito, y se han empleado para predecir la calidad del producto final (e.g. el índice de formación o la resistencia del papel) mediante el desarrollo de modelos basados en medidas procedentes del final de la parte húmeda de la máquina de papel.
- El tratamiento avanzado de datos, en este caso a través de las redes neuronales, ha sido seleccionado debido a la sustancial mejora de resultados respecto al empleo de métodos como las regresiones múltiples.

- Los modelos muestran el comportamiento de la máquina de papel en condiciones normales. Las correlaciones obtenidas muestran la capacidad de predicción de la calidad del papel a partir de medidas del proceso que puedan ser controladas.
- Las redes neuronales desarrolladas se han validado y entrenado mediante diferentes metodologías. Se concluye que las más adecuadas son:
  - El algoritmo de entrenamiento: en este caso el de Levenberg-Marquardt.
  - La arquitectura de los modelos: con una capa oculta de entre 3 y 7 neuronas.
  - El sistema de validación: Mixta con un 40% a 60% de datos externos.
  - El intervalo de tiempo de entrenamiento: 3 meses (resultado preliminar).
- Se han obtenido errores de predicción del 9.0% en la carga de rotura longitudinal, del 7.6% en la longitud de rotura longitudinal, y del 4.4% en el índice de formación. Estos errores se han mantenido, para datos entre 3 y 6 meses posteriores al desarrollo de las redes neuronales, con cambios sustanciales en la fábrica, en valores del 13%, 17% y 9% respectivamente. A largo plazo, se ha propuesto crear un conjunto de modelos distintos según las condiciones de operación.
- Las medidas del sensor FBRM tienen una gran influencia en los modelos desarrollados. Los modelos, al añadir estas medidas, han mejorado las correlaciones obtenidas en un 25%. Por tanto, la toma en continuo de datos con este sensor mejoraría notablemente la optimización de la calidad del papel a partir de medidas del final de la parte húmeda.
- Se ha desarrollado junto a la Universidad de Tampere (TUT) un sistema de validación dinámica de sensores, de tal forma que, en cuanto la robustez de los modelos desarrollados decaiga, salte una alarma para proceder al reentrenamiento. Este trabajo viene a afianzar la utilidad industrial del trabajo desarrollado.
- Considerando las influencias calculadas, se propone la creación de un sistema de control de la físico-química del final de la parte húmeda a partir de medidas del sensor FBRM. Este sistema se implementará en el sistema inteligente de ayuda a la toma de decisiones que se está desarrollando en HPM. En tal caso los modelos habrán de actualizarse y/o mejorar con el tiempo.

- Con la experiencia adquirida, se han transmitido a la fábrica medidas que permitirían un importante ahorro de tiempo en todo el proceso descrito.

## BIBLIOGRAFÍA

1. Aguiar H.C. y Filho R.M., Modeling and optimization of pulp and paper processes using neural networks, *Computers Chem. Engng.*, Vol. 22, Suppl., pp S981-S984. 1998.
2. Aguiar H.C. y Filho R.M., Neural network and hybrid model: a discussion about different modeling techniques to predict the pulping degree with industrial data, *Chem. Eng. Sci.*, Vol. 56, No. 2, pp 565-570. 2001.
3. Aguiar H.C., Filho R.M., Pasquali S.M. y de Jesus R., A predictive hybrid model for pulping process and pulp properties, 52nd APPITA annual general conference, Brisbane, Australia, 11-14 May, Vol. 2, pp 447-451. 1998.
4. Alanen R., Analysis of electrical energy consumption and neural network estimation and forecasting of loads in a paper mill, VTT Publications 424, Espoo, Finland: VTT Technical Research Centre of Finland, ISBN 9513855910, 136pp. 2000.
5. Alhoniemi E., Analysis of pulping data using the Self-Organizing Map, *Tappi J.*, Vol. 83, No. 7, p 66. 2000.
6. Al-Mutawa S. y Moon Y.B., A connectionist expert system approach for representing a press operator's machine-specific knowledge, *TAGA Proceedings 1994 (TAGA)*, Session: Process Management in the Graphic Arts, Vol. 1, pp 527-541. 1994.
7. Alonso A., Blanco A., Negro C. y San Pío I., Validation as a crucial step for improving robustness of models: application to paper quality predictions, *COST action E36 modelling and simulation in pulp and paper industry*, Espoo, Finland, 6 Oct., pp 39-47. 2005.
8. Alonso A., Blanco A., Negro C., Tijero J. y San Pío I., Application of advanced data treatment to predict paper properties, *Proceeding of the 5<sup>th</sup> MathMod Conference*, Vienna, Austria, 8-10 Feb., 7pp. 2006
9. Alonso A., Negro C., Blanco A. y Tijero J., Simulación dinámica de una fábrica de fibrocemento, *Ing. Quim.*, XXXVIII (440), pp 116-119. 2006.
10. Anon, Filaments replace asbestos, *Nonwovens Mark*, Vol. 5, No. 6, 1990.
11. Antti H., Alexandersson D., Sjöström M. y Wallbäcks L., Detection of kappa number distributions in kraft pulps using NIR spectroscopy and multivariate calibration, *Tappi J.*, Vol.83, 3, pp 102-108. 2000.
12. Aspapel, [www.aspapel.es](http://www.aspapel.es). 2014.
13. Back A., Juhola H., Kiviniemi J. y Lindberg T., The variable data mine, *Digital Demand*, No. 2, pp 56-67. 2000.

14. Baines G.H., Hayes R.L. y Stabell J.L., Predicting boiler emissions with neural networks, *Tappi J.*, Vol. 80, No. 5, pp 57-61. 1997.
15. Bard J., Patton J. y Musavi M., Using RBF neural networks and a fuzzy logic controller to stabilize wood pulp freeness, *Proceedings of International Joint Conference on Neural Networks (IJCNN)*, CD IEEE Catalog # 99CH36339C, ISBN 0-7803-5532-6, Washington DC, July 10-16, pp 4247-4252. 1999.
16. Beaverstock M. y Wolchina K., Neural Network Helps G-P Ashdown Mill Improve Brownstock Washer Operation, *Pulp Pap.*, Vol. 66, No. 9, pp 134-136. 1992.
17. Beaverstock M.C. y Hinson M.C., Pulp & Paper Applications of Neural Networks, 1993 TAPPI-ISA PUPID Process Control Conference held 21-25 Mar. 1993 at Nashville, TN, USA, pp 201-205. 1993.
18. Becerra E.M., Joaquim A.P. y Savastano H., Some Properties of Fiber-Cement Composites with Selected Fibers, *Conferência Brasileira de Materiais e Tecnologias Não-Convencionais: Habitações e Infra-Estrutura de Interesse Social Brasil-NOCMAT*, Pirassununga, SP, Brasil, Oct 29 – Nov 3. 2004.
19. Belarbi K., Bettou K. y Mezaache A., Fuzzy neural networks for estimation and fuzzy controller design: simulation study for a pulp batch digester, *Journal of Process Control*, Vol. 10, pp 35-41. 2000.
20. Billa E., Pastou A., Monties B., Romero J. y Koukios E.G., Multivariate chemometric analysis of the fluorescence spectra of eucalyptus wood, *Industrial Crops and Products* Vol. 11, pp 187-196. 2000.
21. Bissessur Y., Martin E.B. y Morris A.J., Monitoring the performance of the paper making process, *Control Eng. Pract.*, Vol. 7, No. 11, pp 1357-1368. 1999.
22. Blanco A., Estudio de la floculación en la fabricación del papel, Dpto. Ingeniería Química, Universidad Complutense de Madrid. 1994.
23. Blanco A., Alonso A., Negro C. y San Pío I., Advanced data treatment to improve quality in a newsprint machine, *Inv. Téc. Pap.*, 150(40), pp 115-121. 2005.
24. Blanco A., Alonso A., Negro C. y San Pío I., Advanced data treatment to improve quality in a newsprint machine, *Proceedings of the "Simposium Internacional: Nuevos Desarrollos en Tecnologías del Reciclado del Papel"*, Instituto Papelero Español, Barcelona, Spain. 19-20 May 2005.
25. Blanco A., Alonso A., Negro C. y Tijero J., Application of advance data treatment to predict paper properties, *Math. Comp. Model. Dyn.* 15(5), pp 453-462. 2009.

26. Blanco A., Fuente E., Alonso A. y Negro C., Optimal use of flocculants on the manufacture of fibre cement materials by the Hatschek process, *Construction and Building Materials* 24, pp 158–164. 2010.
27. Bonissone P.P., Chen Y.-T. y Khedkar P.S., System and method for predicting a web break in a paper machine, United States Patent 5,942,689. 1997.
28. Box G., Hunter W.G. y Hunter J.S., *Statistics for experimenters*, 1ª ed., John Wiley & sons, Inc., New York. 1978.
29. Broeren L.A. y Smith B.A., Process Optimization with Neural Network Software, *Prog. Pap. Recycling*, Vol. 5, No. 2, pp 95-98. 1996.
30. Bucolo M., Fortuna L., Nelke M., Rizzo A. y Sciacca T., Prediction models for the corrosion phenomena in pulp & paper plant, *Control Engineering Practice*, Vol. 10, 227-237. 2002.
31. Budaraju S., Soft sensors for predicting sheet quality properties during paper manufacture, 2001 Engineering, finishing and converting conference, San Antonio, TX, USA, ISBN 1930657838. 16-20 Sept (held 2-6 Dec 2001), 9 pp. 2001.
32. Campoy-Cervera P., Muñoz-García D.F., Pena D. y Calderón-Martínez J.A., Automatic Generation of Digital Filters by NN Based Learning: An Application on Paper Pulp Inspection, *Lect. Notes Comput. Sci.*, No. 2085, pp 235-245. 2001.
33. Cánavos G.C., *Probabilidad y estadística. Aplicaciones y métodos*, Mc Graw Hill, . 1992.
34. Carvalho P., Costa N., Ribeiro B. y Dourado A., Industrial visual inspection of time granules by neural networks, *Computers ind. Engng.*, Vol. 35 Nos. 3-4, 539-542. 1998.
35. CEPI Sustainability Report 2005.
36. Chinnam R.B., Support vector machines for recognizing shifts in correlated and other manufacturing processes, *Int. J. Prod. Res.*, Vol. 40, No. 17, 4449-4466. 2002.
37. Chitra S.P., Use Neural Networks for Problem Solving, *Chem. Eng. Prog.*, Vol. 89, No. 4, pp 44-52. 1993.
38. Chiu C.C. y Occeña L.G., Neural models for characterization and interpretation of hardwood internal defect configurations, ANNIE'95 ARTIFICIAL NEURAL NETWORKS IN ENGINEERING Artificial Neural Networks, Fuzzy Logic and Evolutionary Programming for Designing Smart Engineering Systems, St Louis, USA, pp 905-910. 1995.

39. Cook D.F. y Chiu C.C., Using radial basis function neural networks to recognize shifts in correlated manufacturing process parameters, IIE Transactions, Vol. 30, pp 227-234. 1998.
40. Coultz, R., The relationship between wood pulp fiber cement composite performance, 49th Appita Annual Conference. pp.411-417, 1995.
41. Cristini G., Gentili G.B., Salvador C., Bonifacio F. y Perati U., Presscan, una nueva herramienta para evaluar la eficacia de las vestiduras de prensas, El Papel, Vol. 107, Octubre, pp 48-53. 2003.
42. De Almeida G.M., Cardoso M. y Park S.W., Detecting an abnormality in a recovery boiler using dynamic multivariate data analysis with parallel coordinate plots, Appita Journal, Vol. 65, No. 1, Enero-Marzo, pp 78-86. 2012.
43. De Almeida G.M. y Park S.W., Monitoring of abnormal situations in continuous industrial processes. Case study: multiple effect evaporation system, O. Papel Vol. 74, No. 12, Diciembre, pp 67-72. 2013.
44. DeCicco J., Improving Efficiency and Product Quality by Optimizing Steady State Neural Network Process Models, 2001 TAPPI/ISA-PUPID Process control, electrical, and information conference, San Antonio, TX, USA, session 3, 25-29 Mar, ISBN 1930657617, 7pp. 2001.
45. Dufour P., Bhartiya S., English T.J., Gatzke E.P., Dhurjati P.S. y Doyle F.J., Fault detection in a continuous pulp digester, On line fault detection and supervision in the chemical process industries 2001, Jejudo Island, Korea, ISBN 0080436803, 7-8 June 2001, pp 93-98. 2001.
46. Edwards P.J. y Murray A.F., Neural networks for quality prediction in papermaking, 2001 TAPPI/ISA-PUPID Process control, electrical, and information conference, San Antonio, TX, USA, session 3, ISBN 1930657617. 25-29 Mar, 6pp. 2001.
47. Edwards P.J., Murray A.F., Papadopoulos G., Wallace A.R. y Barnard J., The application of neural networks to the paper-making industry, ESANN'1999 proceedings - European Symposium on Artificial Neural Networks Bruges (Belgium), 21-23 April 1999, D-Facto public., ISBN 2-600049-9-X, pp 69-74. 1999.
48. Edwards P.J., Murray A.F., Papadopoulos G., Wallace A.R., Barnard J. y Smith G., Paper Curl Prediction and Control Using Neural Networks, Tappi Journal, Vol. 82; No. 7, pp 145-151. 1999.
49. Edwards P.J., Peacock A.M., Renshaw D., Hannah J.M. y Murray A.F., Minimizing Risk Using Prediction Uncertainty in Neural Network Estimation Fusion and Its Application to Papermaking, IEEE Transactions on Neural Networks, Vol. 13, No. 3, pp 726-731. 2002.

50. Elman J.L., Finding Structure in Time, *Cognitive Science*, Vol. 14, pp 179-211, 1990.
51. Fadum O., An Introduction to Artificial Intelligence, *Pulp Pap.*, Vol. 67, No. 3, suppl. pp 84-90, 92. 1993.
52. Farzadeh H., Rippon P. y Olofsson J., Mill-wide information system at Slave Lake Pulp Corporation, *Pulp Pap. Can.*, Vol. 98, No. 11, T431-T434. 1997.
53. Finchem K., Neural network technology moves toward mainstream control use, *Pulp Pap.*, Vol. 72, No. 4, pp 63-64, 67-68. 1998.
54. Fuente E., Mecanismos y cinética de los procesos de floculación en la fabricación de papel, Dpto. Ingeniería Química, Universidad Complutense de Madrid. 2004.
55. Fuente E., Jarabo R., Moral A., Negro C. y Izquierdo L., Effect of Sepiolite on the Behaviour of Fibre Cement Suspensions in the Manufacture of Fibre-Reinforced Cement, 11<sup>th</sup>. Inorganic-Bonded Fibre Composites Conference IIBCC, Madrid, Nov. 5-7. 2008.
56. Furumoto H., Apparatus for the operation of a plant for producing deinked pulp with state analysers constructed in the form of neural networks for the waste paper suspension, United States Patent 5,841,671, . 1998.
57. Furumoto H., Gerdemann U. y Zeiner G., Method for process management in paper and cardboard manufacture, United States Patent 6,187,145, . 2001.
58. Furumoto H., Method and device for process control in cellulose and paper manufacture, United States Patent 6,398,914, . 2002.
59. Gyaneshwar M., Hart D. y Scott W.E., The development of mathematical models for predicting sizing, strength, and opacity on the Miami University Pilot Paper Machine, PPI This Week 2000 TAPPI Papermakers conference and trade fair, Vancouver, BC, Canada, 16-19 Apr, Book 2, ISBN 0898529638, pp 413-443. 2000.
60. Haataja K., Leiviska K. y Sutinen R., Kappa Number Estimation with Neural Networks, XIV IMEKO world congress. New measurement - challenges and visions. Vol. XA, Tampere, Finland, 1-6 June 1997. Helsinki, Finland: Finnish Society of Automation, ISBN 952-5183-04-1, pp 1-5 (236pp). 1997.
61. Hagan M.T., Demuth H.B. y Beale M., *Neural Network Design*, PWS Publishing Company, Boston, USA, . 1996.
62. Harrison R.P., Leroux R. y Stuart P.R., Multivariate analysis of refiner operating data from a TMP newsprint mill, *Pulp. Pap. Can.*, Vol. 105, No. 4, pp T79-T82. 2004.
63. Harvey S. and Harvey R., An introduction to artificial intelligence, *Appita Journal*, Vol. 51, No. 1, pp 20-24. 1998.

64. Hebb D.O., *The Organization of Behavior*, Chapters 1, 7, 13. New York Wiley, 1949.
65. Himmelblau D., *Process Analysis by Statistical Methods*, 1<sup>a</sup> ed., John Wiley & sons, Inc., New York, . 1969.
66. Horton R.R. y Shuman L., *Neural network modelling of power and recovery boilers*, *Fundamental advances and innovations in the pulp and paper industry*, AIChE symposium series Vol. 95, No. 322, New York, NY, USA. American Institute of Chemical Engineers. ISBN 0816908168, pp 173-179. 1999.
67. Horton R.R. y Shuman L., *Predictive emissions monitoring for a paper mill power boiler*, 2001 TAPPI/ISA-PUPID Process control, electrical, and information conference, San Antonio, TX, USA, session 2, ISBN 1930657617. 25-29 Mar, 10pp. 2001.
68. Horton R.R., Denlinger M.A., Lien S.J., Schmidl W. y Grace T.M., *Artificial neural network modeling of a kraft recovery boiler*, *International chemical recovery conference*, Tampa, FL, USA, vol. 1, ISBN 0-89852-716-3. 1-4 June, pp 283-298. 1998.
69. Ingman L.C., *Utilization of neural network technology for some pulp and paper industry applications*, *Process control, electrical and information conference - ISA-PUPID 39th annual symposium*, Williamsburg, ISBN 0898529611. 26-30 March, pp 115-120. 2000.
70. James R., *Open wide for the latest automation advances*, *Pulp Pap. Int.*, Vol. 42, No. 3, pp 28, 31-33. 2000.
71. Järvensivu M., Kivivasara J. y Saari K., *Evaluation of various alternatives to reduce TRS emission of the lime kiln*, *TAPPI Proceedings of the 1998 International Chemical Recovery Conference*, pp 519-535. 1998.
72. Järvensivu M., Saari K. y Jämsä-Jounela S.-L., *Intelligent control system of an industrial lime kiln process*, *Control Engineering Practice*, Vol. 9, 589-606. 2001.
73. Joeressen A., *Predicting Corrugated Box Compression Values Through Innovative Software*, *Developments in manufacture, technology and markets for corrugated board*, Manchester, UK, 17-18 Sept, 4pp. 2001.
74. Kajanto I., *Wet End Troubleshooting With Analysis Of On-line Data*, *Scientific & Technical Advances In Wet End Chemistry*, Third Major Pira International Conference, Vienna (Austria), 22-23 May., 2002.
75. Kangas P., Pajarre R., Nappa M. y Koukkari P., *Multi-phase thermodynamic modelling of pulp suspensions: review of the methodology*, *Nord. Pulp Pap. Res. J.*, Vol. 27, No. 3, pp 604-612. 2012.

76. Karrila S. y Rezak S., Review, developments and pulp and paper research applications of data reduction with neural networks, TAPPI 2002 Technology Submit Proceedings, Atlanta, GA, USA, session 8. 3-7 Mar., 16pp. 2002.
77. Keller P.E., Kouzes R.T., Kangas L.J. y Hashem S., Neural Network Based Sensor Systems for Manufacturing Applications, Advanced Information Systems and Technology Conference in Williamsburg, VA, USA, 28-30 March, . 1994.
78. Keski-Santti J., Neural networks in the production optimization of a kraft pulp bleach plant, Acta Universitatis Ouluensis, Technica C 280, University of Oulu Oulu, Finland, 110pp. 2007.
79. Kohonen T., Self Organization and Associative Memory, 2<sup>nd</sup> ed., Chapters 13,14. Springer-Verlag, Berlín. 1987.
80. Konkari Koski K. y Alonso A., Dynamic verification for soft sensor applications, Control Systems Pan-Pacific Conference, Vancouver, BC, Canada, 16-18 Junio, pp 9-14. 2008.
81. Kooi S.B.L. y Khorasani K., Control of the woodchip refiner using neural networks, Tappi Journal, Vol. 75, No. 6, pp 156-162. 1992.
82. Kosunen J., Van Fleet R. y Forslund Ö., How can new control methods improve pulp mill performance, Pap. Asia, Vol. 13, No. 3, pp 285-304. 1997.
83. Krenchel, H., Reseca Laboratory Technical University of Denmark Internal Report, No 1; 18, 1972.
84. Kumar A. y Hand V.C., Feasibility of Using Genetic Algorithms and Neural Networks to Predict and Optimize Coated Paper and Board Brightness, Ind. Eng. Chem. Res., Vol. 39, No. 12, pp 4956-4962. 2000.
85. Kumar A. y Hand V.C., Using Genetic Algorithms and Neural Networks To Predict And Optimize Coated Board Brightness, TAPPI 99 ""Preparing for the next millennium"", Atlanta, GA, USA, Book 1, ISBN 0-89852-734-1. 1-4 Mar, pp 161-170. 1999.
86. Kumar R., Ray A.K. y Mukherjee S., Artificial neural network modeling and control for pressurized head box of paper machine, IPPTA Vol. 22, No. 2, Abril-Junio, pp 103-107. 2010.
87. Laitinen-Vellonen S., Meted and system for monitoring and analyzing a paper manufacturing process, Finlandia, WO 01/75222, PCT/FI01/00324. 2001.
88. Lampe U., Muhlsteff J., Pastusiak R., Meixner H., Furumoto H., Hartenstein H., Anderson L. y Skoglund A., On-line-system for controlling green liquor quality of the kraft process using NIR-spectroscopy, 11th International symposium on wood and pulping chemistry, Nice, France, vol. III, Poster presentations, 11-14 June, pp 621-624. 2001.

89. Lanouette R., Thibault J. y Valade J.L., Improvement of modeling D-optimal design data with neural networks, 83rd Annual meeting technical section - paper, people, progress, Montreal, Que, Canada, Preprints A, ISBN 1-896742-09-2. 28-31 Jan, pp A1-A7. 1997.
90. Lanouette R., Thibault J. y Valade J.L., Improvement of modeling D-Optimal design data with neural networks, Pulp Pap. Can., Vol. 99, No. 9, 298-302. 1998.
91. Lansiluoto A., Back B., Vanharanta H. y Visa A., An analysis of economic trends in the pulp and paper sector using self-organizing maps, Pap. Puu, Vol. 84, No. 4, pp 246-252. 2002.
92. Laperriere L. y Wasik L., Implementing optimization with process simulation, Tappi Journal, Vol. 1, No. 4, pp 7-12. 2002.
93. Laperriere L. y Wasik L., Modeling and simulation of pulp and paper quality characteristics using neural networks, SOLUTIONS!, Vol. 84, No. 10, p 59. 2001.
94. Lenz S., Koerbitz R. y Rudd J., Neural Network Modeling for Paper Property Predictions, 2001 TAPPI/ISA-PUPID Process control, electrical, and information conference, San Antonio, TX, USA, session 3, ISBN 1930657617. 25-29 Mar, 10pp. 2001.
95. Leppäkoski H., Loading calculation system for a roll set using a neural network, Finlandia, WO 01/96967, PCT/FI01/00545. 2001.
96. Li Y., Laperriere L. y Lanouette R., A TMP simulation model based on multivariate analysis, 93<sup>rd</sup> Annual meeting of the Pulp and Paper Technical Association of Canada, PAPTAC, Montreal, QC, Canada, 5-9 Febrero, ppA25-A30. 2007.
97. Martens H. y Naes T., Multivariate calibration, John Wiley & Sons, Chichester. 1998.
98. Martin G., Consider Soft Sensors, Chem. Eng. Prog., Vol. 93, No. 7, pp 66-70. 1997.
99. Martinelli S.H.S., Neitzel I. y Vieira O., Defect detection by neural networks. Application: secondary air system in a chemical recovery boiler, Papel, Vol. 69, No. 8, Agosto, pp 47-62. 2008.
100. Masmoudi R.A., Rapid prediction of effluent biochemical oxygen demand for improved environmental control, Tappi J., Vol. 82, No. 10, pp 111-119. 1999.
101. Matlab 6.5 R13, Manual de Usuario y Ayuda del programa en relación al Toolbox sobre Redes Neuronales, The Mathworks Inc., . 2002.
102. Milosavljevic N. y Heikkilä P., Modeling a Scrubber Using Feed-Forward Neural Networks, Tappi Journal, Vol. 82, No. 3, pp 197-201. 1999.

103. Mine F.H., Figueiredo L.S. y Teixeira R.A., Optimising the oxygen delignification process, *Papel* Vol. 71, No. 12, Diciembre, pp 51-63. 2010.
104. Miyanishi T. y Shimada H., Using Neural Networks to Diagnose Web Breaks on a Newsprint Paper Machine, *Tappi Journal*, Vol. 81, No. 9, pp 163-170. 1998.
105. Musavi M.T., Domnisoru C., Smith G., Coughlin D.R. y Gould A.L., A neuro-fuzzy system for prediction of pulp digester K-number, *Proceedings of International Joint Conference on Neural Networks (IJCNN)*, CD IEEE Catalog # 99CH36339C, ISBN 0-7803-5532-6, Washington DC, US, pp 4253-4258. 1999.
106. Negro C., Alonso A., Blanco A. y Tijero J., Breaking load and bending strength prediction in manufacture of fibre cement composites using Artificial Neural Networks and a flocculation sensor, *Composites Part A*. 36(12), pp 1617-1626. 2005.
107. Negro C., Alonso A., Blanco A. y Tijero J., Optimisation of fibre cement composites process, *Ind. Eng. Chem. Res.* 45(1), pp 197-205. 2006.
108. Oliveira-Esquerre K.P., Mori M. y Bruns R.E., Simulation of industrial wastewater treatment plant using artificial neural networks and principal component analysis, *Brazilian Journal of Chemical Engineering*, Vol. 19, No. 4, pp 365-370. 2002.
109. ORDEN de 7 de diciembre de 2001 por la que se modifica el anexo I del Real Decreto 1406/1989, de 10 de noviembre, por el que se imponen limitaciones a la comercialización y al uso de ciertas sustancias y preparados peligrosos.
110. Patrick K.L., Neural Network Keeps BSW Filtrate Solids at Maximum, Uniform Levels, *Pulp Pap.*, Vol. 65, No. 3, pp 55-58. 1991.
111. Phung T. y Nguyen N.G., Data-Mining application in Paper Quality Prediction on paper machine, *Pulp and Paper Technical Association of Canada: 89th annual meeting*, 4pp. 2003.
112. Pillai B., Adaptation of neural network and fuzzy logic for the wet-end control and process management of paper or board machines: a tool-making approach, *Acta Polytechnica Scandinavica Mechanical Engineering Series* 138, Espoo, Finland: The Finnish Academy of Technology, ISBN 951-666-511-X, 178pp. 1999.
113. Plouff M.T., Prediction and optimization of sizing response using adaptive machine learning and integrated management of wet-end chemistry, *TAPPI 2002 Technology Submit Proceedings*, Atlanta, GA, USA, session 11. 3-7 Mar., 12pp. 2002.
114. Podkulski D.E., How Do New Process Analyzers Measure Up?, *Chem. Eng. Prog.*, Vol. 93, No. 10, pp 33-46. 1997.

115. Presser C.C., Data mining, Información obtenida de Monografías.com - Data mining, . 2001.
116. Pulkkinen M., Saastamoinen M. y Skyttä M., Kotka fuzzifies its kappa control, Pulp Pap. Eur., Vol. 2, No. 10, pp 30-32. 1997.
117. Qian Y., Tessier P. y Dumont G.A., Modeling a Wood-Chip Refiner Using Artificial Neural Networks, Tappi Journal, Vol. 78, No. 6, pp 167-174. 1995.
118. Rajesh K., Pradeep J. y Ray A.K., Development of strategy of wet end retention control through simulation of classical PID and artificial neural network models, IPPTA Vol. 23, No. 2, Abril-Junio, pp 179-186. 2011.
119. Ray A.K., Juneja P.K., Dhote A., Bawari M. y Kumar R., Control of brown stock washing process in a paper mill using ANN strategy, IPPTA Vol. 22, No. 1, Enero-Marzo, pp 99-103. 2010.
120. Rodden G., Many new offerings help make the mill a safer place to work, Pulp Pap. Can., Vol. 102, No. 3, pp 11-13. 2001.
121. Rooke P.E. y Wang H., Applying combined neural network and physical modelling to the retention process in papermaking, Appita Journal, Vol. 55, No. 4, pp 281-293. 2002.
122. Rudd J.B., Prediction and control of pulping processes using neural network models, 80th Annual Meeting Technical Section held at Montreal, Canada, Preprints B, ISBN 1-895288-56-8. 3-4 Feb, pp B169-B173. 1994.
123. Rudd J.B., Using a Neural Network Controller for Advanced Control Applications, 1991 Engineering Conference held 30 Sept.-3 Oct. 1991 at Nashville, TN, USA, Book 1, pp 101-114. 1991.
124. Rudd J.B., Using a neural network system for advanced process control, Tappi Journal, Vol. 74, No. 10, pp 153-159. 1991.
125. Ruuska H., Improving paper machine efficiency by reducing break losses and improving quality, Viconsys Oy Pub. Journal. 2009.
126. Ryan R., The process automation (r)evolution, PIMA's papermaker, Vol. 80, No. 9, pp 44,46-47. 1998.
127. Saarela A., ABB pulp defect analyser: online dirt count measurement, 94<sup>th</sup> annual meeting preprints PAPTAC, Montreal, QC, Canada, 6-7 Febrero, pp B463-B466. 2008.
128. Saarela O., Multivariate autoregressive analysis in locating the origin of fluctuation in continuous industrial processes, Tampere University of Technology Publications 366, Thesis for the degree of Doctor of Technology, Tampere (Finland). 2002.

129. San Pío I., Metodología para la optimización de la floculación en la fabricación de fibrocemento sin amianto, Dpto. Ingeniería Química, Universidad Complutense de Madrid. 2003.
130. Sarimveis H. y Retsina T., Tissue softness prediction using neural network methodologies, 86th Annual meeting, Montreal, Que, Canada, Preprints A, ISBN 189674253X. 1-3 Feb, pp A27-A30. 2000.
131. Sarimveis H., Alexandridis A., Tsekouras G. y Bafas G., A fast and efficient algorithm for training radial basis function neural networks based on a fuzzy partition of the input space, Ind. Eng. Chem. Res., Vol. 41, pp 751-759. 2002.
132. Sasaki T., Position correspondence identification algorithm in basis weight profile control, XIV IMEKO World Congress/CD Symposium, Finland, June 1997, pp. 139-144, pp 139-144. 1997.
133. Scharcanski J. y Dodson C.T.J., A new simulator for paper forming using neural network methods, Appita, Vol. 48, No. 5, pp 347-350. 1995.
134. Scharcanski J. y Dodson C.T.J., Neural Network Model for Paper Forming Process, Conference record of 1996 Annual Pulp and Paper Industry Technical Conference: Sheraton Civic Center, Birmingham, AL, June 10-14, pp 236-255. 1996.
135. Schweiger C.A. y Rudd J.B., Prediction and control of paper machine parameters using adaptive technologies in process modelling, Tappi Journal, Vol. 77, No. 11, pp 201-208. 1994.
136. Smith B.A. y Broeren L.A., A tool for process optimization: neural network software, TAPPI Proceedings of the 1996 Recycling symposium, New Orleans, LA, USA, ISBN 0-89852-657-4. 3-6 Mar, pp 163-187. 1996.
137. Smith G.C., Wrobel C.L. y Stengel D.L., Modeling TRS and Sulphur Dioxide Emissions from a Kraft Recovery Boiler Using an Artificial Neural Network, Tappi J., Vol. 83, No. 11, p 69. 2000.
138. Soroushian, P. y Marikunte, S., Reinforcement of cement based materials with cellulose fibers,, Am. Conct. Inst.. SP, 124 (Thin Sect. Fiber Reinf. Concr. Ferrocem.) pp.99-124, 1990.
139. Sparén A., Renberg L., Furusjö E., Ahlqvist-Hillforth C. y Danielsson L.G., Determination of kappa number reduction in pulp and COD in bleach plant effluents using multiwavelength spectrometry and multivariate calibration, Tappi J., Vol. 2, No. 1, pp 16-21. 2003.
140. Speagel M., Estadística, Mc Graw Hill, . 1991.
141. Speiser C.R., Krähenbühl M. y Walter R., Tomorrow's world? I'll just consult my model, Pulp Pap. Int., , pp 30-31. 1996.

142. Stapley C.E., Butner R.E., Kangas M.Y.O., Broeren L.A. y Smith B.A., Tools for strategic analysis: neural networking, *Pulp Pap.*, Vol. 71, No. 1, pp 89-90,93-96. 1997.
143. Sui O.S., Sanche L., Mills C., Smith W., Smith G. y Douglas T., Model based pulp quality control of TMP refiner, *TAPPI Proceedings of the 1998 Pulping Conference*, pp 295-308. 1998.
144. Suojärvi M., Neural Network for Estimation of Quality, XIV IMEKO world congress. New measurement - challenges and visions. Vol. XA, Tampere, Finland, 1-6 June 1997, Helsinki, Finland: Finnish Society of Automation, 236pp. ISBN 952-5183-04-1, pp 48-52. 1997.
145. Szladow A.J., Mills D. y Fry R., Improving energy efficiency with intelligent systems, 87th Annual meeting, Montreal, Canada, Preprint C, ISBN 1-896742-68-8. 30 Jan. - 1 Feb, pp C53-C56. 2001.
146. Tchaban T., Taylor M.J. y Griffin J.P., Establishing impacts of the inputs in a feedforward neural network, *Neural Comput. & Applic.*, Vol. 7., pp 309-317. 1998.
147. Thibault J., Taylor D., Yanofsky C., Lanouette R., Fonteix C. y Zaras K., Multicriteria optimization of a high yield pulping process with rough sets, *Chemical Engineering Science*, Vol. 58, pp 203-213. 2003.
148. Tsoukalas L.H. y Uhrig R.E., *Fuzzy and Neural Approaches in Engineering*, Ed. Wiley Interscience, . 1997.
149. Ullman J.D., Publicaciones acerca de data mining en la página web <http://www-db.stanford.edu/~ullman/mining/overview.pdf>, -, . 2002.
150. URALITA, *Manual para la Tecnología del Fibrocemento*, 1995.
151. Vaughan J.S., Gottlieb P.M., Lee S.-C. y Beilstein J.R., The Development of a Neural Network Soft Sensor for Chlorine Dioxide Stage Brightness Control, *TAPPI 99 ""Preparing for the next millennium""*, Atlanta, GA, USA, Book 1, ISBN 0-89852-734-1. 1-4 Mar, pp 147-159. 1999.
152. Verikas A., Malmqvist K. y Bacauskiene M., Combining neural networks, fuzzy sets, and the evidence theory based techniques for detecting colour specks, *Journal of Intelligent and Fuzzy Systems*, Vol. 10, pp 117-130. 2001.
153. Verikas A., Malmqvist K., Bacauskiene M. y Bergman L., Monitoring the de-inking process through neural network-based colour image analysis, *Neural Comput. & Applic.*, Vol. 9, pp 142-151. 2000.
154. Virkki-Hatakka T. y Bulsari A., Scalability of neural network models makes industrial use easier, *Paperi ja Puu - Paper and Timber*, Vol. 84, No. 7, pp 463-466. 2002.

155. Wang H., Wang A.P. y Duncan S.R., Advanced process control in paper and board making, Pira Technology Series, Pira International, Surrey, UK, . 1997.
156. Welp E.G., Wang D. y Kleinert A., A regulation concept for web-spreading equipment in web processing machines on the basis of neural networks, Proceedings of the sixth international conference on web handling (IWEB), Stillwater, OK, USA, 10-13 June 2001, pp 547-565. 2002.
157. Wifrow B. y Hoff M., Adaptive switching circuits, IRE Wescon convention record, USA, Part 4, pp 96-104. 1960.
158. Wold S. y Kettaneh-Wold N., Improving pulp and paper process diagnostics and knowledge by means of multivariate analytical techniques (MVA), Pulp. Pap. Can, Vol. 104, No. 5, pp T121-T123. 2003.
159. Xie T., Ghiaasiaan S.M. y Karrila S., Flow regime identification in gas/liquid/pulp fiber slurry flows based on pressure fluctuations using artificial neural networks, Ind. Eng. Chem. Res., Vol. 42, pp 7017-7024. 2003.
160. Zainuddin Z., Daud W.R.W., Pauline O. y Shafie A., Wavelet neural networks applied to pulping of oil palm fronds, Bioresour. Technol. Vol. 102, No. 23, Diciembre, pp 10978-10986. 2011.
161. Zheng L.L., Mc Avoy T.J., Huang Y y Chen G., Application of multivariate statistical analysis in batch processes, Ind. Eng. Chem. Res., Vol. 40, No. 7, pp 1641-1649. 2001.
162. Zhu J., Xia Q., Rao M. y Zurcher J., A neural network for modeling pulp process, Pulp Pap. Can., Vol. 98, No. 9, pp 35-38. 1997.
163. Zhu J., Xia Q., Rao M. y Zurcher J., An artificial neural network integrated environment for modeling and simulation in pulp and paper industry, 82nd Annual Meeting Technical Section - creating an environment for the future, Montreal, Canada, Preprints A, ISBN 1-895288-92-4. 30 Jan.-2 Feb, pp A29-A33. 1996.

## ÍNDICE DE FIGURAS Y TABLAS

Figura 1.1 – Esquema de trabajo de la tesis doctoral.....	15
Figura 2.1 – Esquema de la etapa de formación de la placa de fibrocemento.....	20
Figura 2.2 – Esquema del ensayo para la determinación del Índice de Clase.....	25
Figura 2.3 – Esquema del ensayo para determinación del Momento Flector.....	26
Figura 3.1 – Ejemplo de una máquina de papel.....	29
Figura 3.2 - Red neuronal sencilla, del tipo “alimentación hacia delante”.....	42
Figura 3.3 – Esquema de un perceptrón multicapa de 3 capas. Fuente: Hagan y col., 1995.....	43
Figura 3.4 - Esquema de una red neuronal empleando el algoritmo de retropropagación (Tsoukalas, L.H. y Uhrig, R.E., 1997). ....	52
Figura 4.1 – Ejemplo de una fábrica de papel integrada. Las diferentes secciones se señalan según número de referencia del capítulo (4.1.2). ....	55
Figura 5.1 - Método de medida de longitudes de cuerda de la sonda FBRM.....	99
Figura 5.2 - Medidor FBRM de Lasentec® en laboratorio (encima) y en fábrica (continuación debajo). ....	100
(Figura 5.2 – Continuación).....	100
Figura 5.3 - Esquema de la sonda FBRM, con sus componentes y detalle del funcionamiento. ....	101
Figura 5.4 – Ventana principal de Matlab®. ....	104
Figura 5.5 – Ventana de edición de archivos de secuencia y funciones. ....	105
Figura 5.6 – Ventana principal de FlowMac, dentro del programa Extend v6.....	108
Figura 5.7 – Ejemplo de creación de diagrama de planta con FlowMac.....	111
Figura 5.8 – Esquema de optimización de la arquitectura de red.....	115
Figura 5.9 – Selección de las mejores redes. El proceso se basa en la búsqueda del mínimo error de validación.....	116
Figura 5.10 – Esquema de la selección de número óptimo de iteraciones.....	118
Figura 5.11 – Esquema de la metodología seguida en el caso del fibrocemento.....	119
Figura 6.1 – Ejemplo de representación gráfica obtenida. Densidad a los 7 días frente al número de cuentas por segundo de partículas entre 10 y 32 $\mu\text{m}$ (Anexo I).....	125
Figura 6.2 – Ejemplo de representación gráfica obtenida. Índice de Clase a los 7 días frente al número de cuentas por segundo de partículas entre 100 y 1000 $\mu\text{m}$ (Anexo I).....	126

Figura 6.3 – Ejemplo de representación gráfica obtenida. Momento Flector a los 7 días frente al número de cuentas por segundo de partículas entre 100 y 1000 $\mu\text{m}$ (Anexo I).....	126
Tabla 6.1 – Coeficientes de correlación ( $R^2$ ) obtenidos para las regresiones lineales. (Gráficas en el anexo I).....	127
Figura 6.4 – Ejemplo de las representaciones obtenidas para valores de densidad en tierno constante, y en este caso igual a 1.92 $\text{g}/\text{cm}^3$ (Anexo II). .....	129
Figura 6.5 – Ejemplo de las representaciones obtenidas para valores de densidad en tierno constante, y en este caso igual a 1.92 $\text{g}/\text{cm}^3$ (Anexo II). .....	129
Tabla 6.2 – Entradas y salidas de la RED-A.....	130
Tabla 6.3 – Parámetros de la RED-A. Valores y criterios de elección. ....	131
Tabla 6.4 – Error medio porcentual para cada variable de salida (RED-A).....	132
Figura 6.6 – Valores reales y predicciones de la RED-A para las muestras de validación.....	132
Tabla 6.5 – Efecto de cada entrada según análisis de pesos, ANN-A. ....	133
Tabla 6.6 – Valores empleados en el diseño de experimentos $2^7$ .....	134
Tabla 6.7 – Suma de efectos significativos estandarizados de cada estadístico del FBRM sobre el $F_s$ a las 48 horas, $F_s$ a los 7 días y $M$ a los 7 días, en el diseño $2^7$ .....	134
Tabla 6.8 – Parámetros de las redes B, C y D. Valores y criterios de elección. ....	135
Figura 6.8 – Valores reales y predicciones de la RED-B para las muestras de validación.....	137
Figura 6.9 – Superficie de respuesta de la RED-1 para el $F_s$ a las 48 horas. (Zona óptima marcada con el círculo) Densidad en tierno = 1.98 $\text{kg}/\text{L}$ .....	139
Figura 6.10 – Datos reales frente a datos predichos para el $F_s$ a los 7 días. 45 muestras de validación. (A= datos predichos; T= datos reales) Gráfico obtenido con Matlab 6.5 R13 tras el entrenamiento de la red.....	140
Figura 6.11 – Valores reales y predicciones de la RED-C para las muestras de validación.....	140
Figura 6.12 – Superficie de respuesta de la RED-C para el $F_s$ a los 7 días. (Zona óptima marcada con el círculo) Densidad en tierno = 1.98 $\text{kg}/\text{L}$ .....	141
Figura 6.13 – Datos reales frente a datos predichos para el $M$ a los 7 días. 45 muestras de validación. (A= datos predichos; T= datos reales) Gráfico obtenido con Matlab 6.5 R13 tras el entrenamiento de la red.....	142

Figura 6.14 – Valores reales y predicciones de la RED-D para las muestras de validación.....	143
Figura 6.15 – Superficie de respuesta de la RED-D para el $M$ a los 7 días. (Zonas óptimas marcada con círculos) Densidad en tierno = 1.98 kg/L.....	143
Tabla 6.9 – Entradas y salidas de las redes E y F.....	144
Tabla 6.10 – Parámetros de la RED-E. Valores y criterios de selección. ....	145
Figura 6.16 – Datos reales frente a datos predichos para la densidad a los 7 días. 26 muestras de validación. (A= datos predichos; T= datos reales) Gráfico obtenido con Matlab 6.5 R13 tras el entrenamiento de la red. ....	146
Tabla 6.11 – Coeficientes de correlación “R” para cada salida (RED-E). ....	146
Figura 6.17 – Superficie de respuesta de la RED-E para el $F_s$ a los 7 días. (Zonas óptimas marcada con círculos) Densidad en tierno = 1.98 kg/L.....	147
Tabla 6.12 – Factores de corrección para el $F_s$ . PVA-A es el perfil de referencia.....	148
Tabla 6.13 – Parámetros de la RED-F. Valores y criterios de selección. ....	149
Tabla 6.14 – Coeficientes de correlación “R” para cada salida (RED-F). ....	150
Figura 6.18 – Valores reales y predicciones de la RED-F para las muestras de validación.....	150
Figura 6.19 – Superficie de respuesta de la RED-F para el $F_s$ a los 7 días. (Zona óptima marcada con un círculo) Densidad en tierno = 1.98 kg/L.....	151
Figura 6.20 – Esquema de conversión de los datos de WinMOPS a KCL-Wedge, a través de ficheros ASCII. ....	156
Figura 6.21 - Esquema de conversión de los datos de WinMOPS a KCL-Wedge, a través de archivos de Excel.....	157
Tabla 6.15 – Tipos de papel producidos en Julio, Agosto y Septiembre de 2004. ....	158
Figura 6.22 – Gráfico de tendencia del tipo de papel vs. tiempo. Los distintos tipos de papel se numeran según tabla 6.15. ....	158
Figura 6.23 – Proceso de selección del tipo de papel. Los valores elegidos se muestran entre las dos líneas horizontales. ....	159
Figura 6.24 – Nuevo gráfico de tendencia tras la eliminación. ....	160
Figura 6.25 – Ejemplos de histograma para algunas de las variables seleccionadas, tomadas con el sensor FBRM. ....	162
Tabla 6.16 – Variables elegidas tras la primera selección. En rojo medidas de la calidad del papel, y en azul, medidas del sensor FBRM. ....	163

Tabla 6.17 – Matriz de correlaciones (Valores “R”) en el entorno de trabajo seleccionado.....	166
Tabla 6.18 – Coeficientes de correlación de los modelos creados según mes y tipo de producción.....	168
Figura 6.26 – Modelo del índice de formación de Agosto, datos de laboratorio y validación del modelo de Julio en Agosto (2004).....	169
Tabla 6.19 – Coeficientes de correlación del periodo complete, comparados con los valores medios de correlación de cada mes por separado. ....	170
Tabla 6.20 – Coeficientes de correlación para los diferentes parámetros de calidad del papel en el modelado con redes neuronales. ....	171
Figura 6.27 – Resultados de la red “ANN-1” comparados con los datos medidos del índice de formación.....	172
Figura 6.28 – Esquema de trabajo general para el modelado de la calidad del papel.....	174
Tabla 6.21 – Errores medios e índices de correlación para cada salida de la red ANN-1B. ....	176
Tabla 6.22 – ANN-1 y ANN-1B: Diferencias y peso de las medidas del sensor FBRM. ....	176
Tabla 6.23 – Errores medios e índices de correlación para cada salida de la red ANN-1C. ....	177
Tabla 6.24 – Diferencia entre las redes ANN-1 y ANN-1C. Comparación medidas FBRM vs. Índice de Floculación.....	177
Figura 6.29 – Errores medios para los diferentes parámetros de calidad obtenidos por modelado con redes neuronales y validación aleatoria (ANN-1) o validación mixta (ANN-2). ....	180
Tabla 6.25 – Errores medios de las redes neuronales desarrolladas en el segundo estudio preliminar. ....	181
Figura 6.30 – Errores cuadráticos medios de entrenamiento y validación (MSE) para una de las redes desarrolladas con algoritmo GDA. ....	183
Figura 6.31 – Errores cuadráticos medios de entrenamiento y validación (MSE) para una de las redes desarrolladas con algoritmo GDA. ....	184
Figura 6.32 – Errores cuadráticos medios de entrenamiento y validación (MSE) para una de las redes desarrolladas con algoritmo LMA. ....	185
Figura 6.33 – Errores cuadráticos medios de entrenamiento y validación (MSE) para una de las redes desarrolladas con algoritmo LMA. ....	186
Tabla 6.26 – Datos empleados en cada grupo desarrollado de redes neuronales.....	186
Tabla 6.27 – Error cuadrático medio para cada una de las redes óptimas seleccionadas para el análisis. Cálculo por grupos de la media del error de simulación cometido. ....	187

Figura 6.34 – Errores de validación y simulación para todos los grupos de redes neuronales creados. El número encima de cada grupo de barras representa el porcentaje de datos externos para validación.....	188
Figura 6.35 – Simulación 1 del índice de formación con la mejor red neuronal, del grupo ANN-3.....	190
Tabla 6.28 – Errores de la simulación 1 para cada variable de salida con la mejor red neuronal, del grupo ANN-3. ....	191
Tabla 6.29 – Errores de la simulación 2 para cada variable de salida con la mejor red neuronal, del grupo ANN-3. ....	191
Figura 6.36 – Simulación 2 de la carga de rotura longitudinal con la mejor red neuronal, del grupo ANN-3.....	191
Tabla 6.30 – Impactos relativos de las entradas sobre cada salida de los modelos (salidas en cabeceras de fondo gris oscuro). Todos los valores restantes son menores de 30. Los impactos positivos se señalan con fondo gris claro, y los negativos con fondo gris oscuro. ....	192
Figura 6.37 – Concepto de validación dinámica de una salida de una red neuronal.....	195
Figura 6.38 – Caso práctico de validación dinámica de la salida de una red neuronal.....	196

## **ANEXOS**

Cada anexo presenta numeración independiente, con el número de anexo precediendo al número de página.

## ANEXO I


### Correlaciones de la calidad del fibrocemento con estadísticos del sensor FBRM.



---



#### ÍNDICE



1.	Relaciones entre la densidad en tierno y todas las variables.....	2
2.	Relaciones entre el número de partículas contadas entre 10 y 32 $\mu\text{m}$ y todas las variables .....	7
3.	Relaciones entre el número de partículas contadas entre 100 y 1000 $\mu\text{m}$ y todas las variables .....	12
4.	Relaciones entre el número de partículas contadas entre 50 y 86 $\mu\text{m}$ y todas las variables .....	17
5.	Relaciones entre el porcentaje de partículas contadas entre 10 y 86 $\mu\text{m}$ respecto a las cuentas totales y todas las variables .....	22
6.	Relaciones entre las cuentas totales puntuales y todas las variables .....	27
7.	Relaciones entre las cuentas totales medias y todas las variables .....	32



### 1. RELACIONES ENTRE LA DENSIDAD EN TIERNO Y TODAS LAS VARIABLES




















2. RELACIONES ENTRE EL NÚMERO DE PARTÍCULAS CONTADAS ENTRE 10 Y 32  $\mu\text{m}$  Y TODAS LAS VARIABLES




















3. RELACIONES ENTRE EL NÚMERO DE PARTÍCULAS CONTADAS ENTRE 100 Y 1000  $\mu\text{m}$  Y TODAS LAS VARIABLES




















4. RELACIONES ENTRE EL NÚMERO DE PARTÍCULAS CONTADAS ENTRE 50 Y 86 μm Y TODAS LAS VARIABLES




















5. RELACIONES ENTRE EL PORCENTAJE DE PARTÍCULAS CONTADAS ENTRE 10 Y 86  $\mu\text{m}$  RESPECTO A LAS CUENTAS TOTALES Y TODAS LAS VARIABLES


















## 6. RELACIONES ENTRE LAS CUENTAS TOTALES PUNTUALES Y TODAS LAS VARIABLES



Se llaman cuentas totales puntuales las obtenidas en el punto concreto de tiempo en el que fue emitido cada paquete de producción en la fábrica.


















## 7. RELACIONES ENTRE LAS CUENTAS TOTALES MEDIAS Y TODAS LAS VARIABLES


Se entiende por cuentas totales medias la media de las cuentas totales entre 5 minutos antes y después de la hora concreta de emisión del paquete seleccionado. (media de 11 valores).












cps total (Sin ponderar, media móvil centrada de 10 minutos)



cps total (Sin ponderar, media móvil centrada de 10 minutos)

## ANEXO II

### Búsqueda de correlaciones entre las variables estudiadas, fijando constante la densidad en tierno.



---



#### ÍNDICE



1.	Representaciones del número de cuentas de partículas de tamaño de 10 á 32 $\mu\text{m}$ frente a las diferentes variables .....	2
1.1.	Con densidad en tierno igual a 1.91 $\text{g}/\text{cm}^3$ .....	2
1.2.	Con densidad en tierno igual a 1.92 $\text{g}/\text{cm}^3$ .....	6
1.3.	Con densidad en tierno igual a 1.93 $\text{g}/\text{cm}^3$ .....	11
1.4.	Con densidad en tierno igual a 1.94 $\text{g}/\text{cm}^3$ .....	15
1.5.	Con densidad en tierno igual a 1.95 $\text{g}/\text{cm}^3$ .....	20
1.6.	Con densidad en tierno igual a 1.96 $\text{g}/\text{cm}^3$ .....	24
1.7.	Con densidad en tierno igual a 1.97 $\text{g}/\text{cm}^3$ .....	29
2.	Representaciones del número de cuentas de partículas de tamaño de 50 á 86 $\mu\text{m}$ frente a las diferentes variables .....	34
2.1.	Con densidad en tierno igual a 1.91 $\text{g}/\text{cm}^3$ .....	34
2.2.	Con densidad en tierno igual a 1.92 $\text{g}/\text{cm}^3$ .....	38
2.3.	Con densidad en tierno igual a 1.93 $\text{g}/\text{cm}^3$ .....	43
2.4.	Con densidad en tierno igual a 1.94 $\text{g}/\text{cm}^3$ .....	47
2.5.	Con densidad en tierno igual a 1.95 $\text{g}/\text{cm}^3$ .....	52
2.6.	Con densidad en tierno igual a 1.96 $\text{g}/\text{cm}^3$ .....	56
2.7.	Con densidad en tierno igual a 1.97 $\text{g}/\text{cm}^3$ .....	61
3.	Representaciones del número de cuentas de partículas de tamaño de 100 á 1000 $\mu\text{m}$ frente a las diferentes variables.....	66
3.1.	Con densidad en tierno igual a 1.91 $\text{g}/\text{cm}^3$ .....	66
3.2.	Con densidad en tierno igual a 1.92 $\text{g}/\text{cm}^3$ .....	70
3.3.	Con densidad en tierno igual a 1.93 $\text{g}/\text{cm}^3$ .....	75
3.4.	Con densidad en tierno igual a 1.94 $\text{g}/\text{cm}^3$ .....	79
3.5.	Con densidad en tierno igual a 1.95 $\text{g}/\text{cm}^3$ .....	84
3.6.	Con densidad en tierno igual a 1.96 $\text{g}/\text{cm}^3$ .....	88
3.7.	Con densidad en tierno igual a 1.97 $\text{g}/\text{cm}^3$ .....	93
4.	Aspectos a tener en cuenta y resultados. ....	98



### 1. REPRESENTACIONES DEL NÚMERO DE CUENTAS DE PARTÍCULAS DE TAMAÑO DE 10 Á 32 μM FRENTE A LAS DIFERENTES VARIABLES


CON DENSIDAD EN TIERNO IGUAL A 1.91 g/cm<sup>3</sup>




















CON DENSIDAD EN TIERNO IGUAL A 1.92 g/cm³




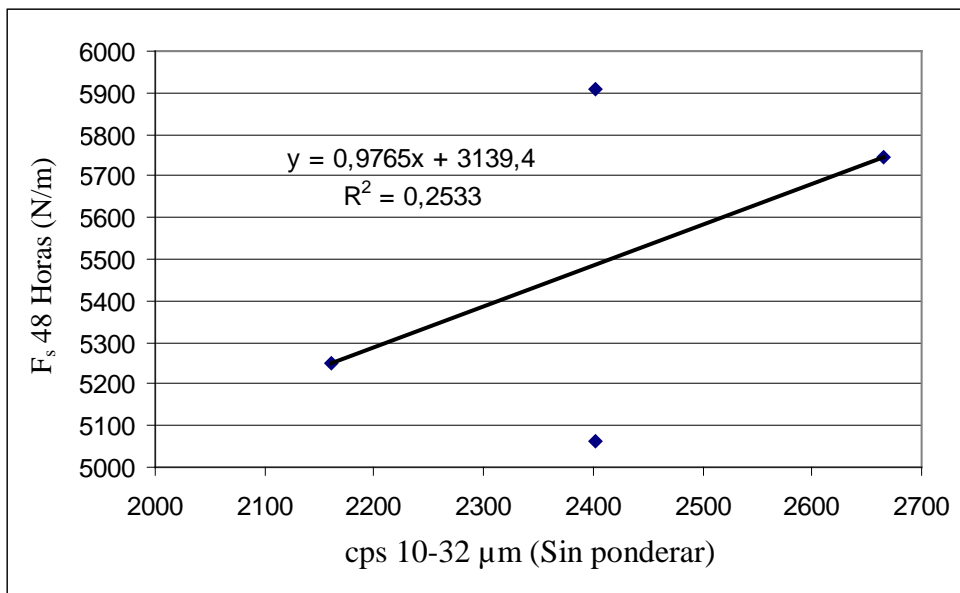















CON DENSIDAD EN TIERNO IGUAL A 1.93 g/cm<sup>3</sup>




















CON DENSIDAD EN TIERNO IGUAL A 1.94 g/cm³




















CON DENSIDAD EN TIERNO IGUAL A 1.95 g/cm<sup>3</sup>




















CON DENSIDAD EN TIERNO IGUAL A 1.96 g/cm³




















CON DENSIDAD EN TIERNO IGUAL A 1.97 g/cm<sup>3</sup>



















## 2. REPRESENTACIONES DEL NÚMERO DE CUENTAS DE PARTÍCULAS DE TAMAÑO DE 50 Á 86 μM FRENTE A LAS DIFERENTES VARIABLES


CON DENSIDAD EN TIERNO IGUAL A 1.91 g/cm<sup>3</sup>




















CON DENSIDAD EN TIERNO IGUAL A 1.92 g/cm<sup>3</sup>




















CON DENSIDAD EN TIERNO IGUAL A 1.93 g/cm<sup>3</sup>




















CON DENSIDAD EN TIERNO IGUAL A 1.94 g/cm<sup>3</sup>




















CON DENSIDAD EN TIERNO IGUAL A 1.95 g/cm<sup>3</sup>




















CON DENSIDAD EN TIERNO IGUAL A 1.96 g/cm³




















CON DENSIDAD EN TIERNO IGUAL A 1.97 g/cm<sup>3</sup>



















### 3. REPRESENTACIONES DEL NÚMERO DE CUENTAS DE PARTÍCULAS DE TAMAÑO DE 100 Á 1000 μM FRENTE A LAS DIFERENTES VARIABLES


CON DENSIDAD EN TIERNO IGUAL A 1.91 g/cm<sup>3</sup>




















CON DENSIDAD EN TIERNO IGUAL A 1.92 g/cm<sup>3</sup>




















CON DENSIDAD EN TIERNO IGUAL A 1.93 g/cm<sup>3</sup>




















CON DENSIDAD EN TIERNO IGUAL A 1.94 g/cm<sup>3</sup>




















CON DENSIDAD EN TIERNO IGUAL A 1.95 g/cm<sup>3</sup>




















CON DENSIDAD EN TIERNO IGUAL A 1.96 g/cm<sup>3</sup>




















CON DENSIDAD EN TIERNO IGUAL A 1.97 g/cm<sup>3</sup>











#### 4. ASPECTOS A TENER EN CUENTA Y RESULTADOS.

Algunos valores de densidad en tierno no han sido representados, bien porque se dispone de datos insuficientes para ello o bien por la imposibilidad de poder compararlos con valores más cercanos (caso de valores de 1.80 a 1.90). Se han representado aquellos que permiten intentar obtener conclusiones de la comparación entre ellos, sin una extrapolación que podría resultar poco eficiente por los pocos datos disponibles en otros rangos de valores.

De entrada, se pueden observar numerosos casos de índices de correlación por encima de 0.5.

La discriminación del comportamiento, para tener mayores garantías, debería comprobarse con bastantes más datos experimentales, al menos para llegar a una conclusión por este tipo de procedimiento.

Tal vez debido al error experimental, o a un comportamiento caótico de propiedades, quedan también numerosos casos de ajustes de muy bajo  $R^2$ , de los cuales en principio no pueden obtener muchas conclusiones salvo, en algún caso, la apreciación de un comportamiento acorde a otras correlaciones.

Cualquier resultado obtenido ha de ser evaluado con precaución, debido a lo complejo de este comportamiento. De hecho, simplemente la escala elegida en la representación puede hacer que una nube de puntos se vea como una línea, estirando un eje y acortando el otro, con lo que se debe tener cuidado con posibles apreciaciones indebidas que lleven a error.

A continuación se detalla algo más el comportamiento que se ha observado respecto a los distintos valores de tamaño de partículas y de densidad en tierno, refiriéndose en las comparaciones al apartado correspondiente donde se encuentran representadas (ejemplo: 1.3 equivale a decir que se trata de representaciones del número de cuentas de partículas de tamaño de 10 a 32  $\mu\text{m}$  frente a las variables proporcionadas, con densidad en tierno igual a 1.93  $\text{g}/\text{cm}^3$ ).

En el apartado 1 se observan comportamientos lineales, salvo en el apartado 1.7, en el cual se observa un posible comportamiento cuadrático en varias de las representaciones, pero sin una tendencia clara de máximos coincidentes o alguna otra posibilidad.

En los casos 2.2, 2.4 y 2.5 se puede apreciar claramente en sus representaciones un comportamiento cuadrático similar en las gráficas

frente a distintos parámetros. El apartado 2.7 presenta una tendencia menos clara, habiendo curvas tanto cóncavas como convexas.

En los apartados 3.1, 3.2 y 3.7 se observan comportamientos cuadráticos en algunos casos con mínimos parecidos entre sí en cada una de ellos. En 3.3 y 3.5 se observa algo parecido pero con los máximos.

En cuanto a tendencias de comportamiento de algún parámetro con la variación de densidad, no se aprecia ninguna significativa.

Se puede observar un cierto parecido en las representaciones para una misma variable y un mismo valor de densidad (por ejemplo, las de 1.3, 2.3 y 3.3 variable a variable). Esto se debe a que el número de cuentas de uno y otro tamaño suelen estar relacionados entre ellos, de tal forma que su relación con las distintas variables guarda un cierto parecido en algunos casos.

## ANEXO III



### Representaciones del efecto de la variación de una entrada a la red sobre sus respuestas.



---



#### ÍNDICE


1.	Variando el número de cuentas de tamaño 1-5 $\mu\text{m}$ .....	2
2.	Variando el número de cuentas de tamaño 5-10 $\mu\text{m}$ .....	5
3.	Variando el número de cuentas de tamaño 10-32 $\mu\text{m}$ .....	9
4.	Variando el número de cuentas de tamaño 32-50 $\mu\text{m}$ .....	12
5.	Variando el número de cuentas de tamaño 50-86 $\mu\text{m}$ .....	16
6.	Variando el número de cuentas de tamaño 86-100 $\mu\text{m}$ .....	19
7.	Variando el número de cuentas de tamaño 100-1000 $\mu\text{m}$ .....	23

### 1. VARIANDO EL NÚMERO DE CUENTAS DE TAMAÑO 1-5 $\mu\text{m}$
















## 2. VARIANDO EL NÚMERO DE CUENTAS DE TAMAÑO 5-10 $\mu\text{m}$
















### 3. VARIANDO EL NÚMERO DE CUENTAS DE TAMAÑO 10-32 $\mu\text{m}$
















**4. VARIANDO EL NÚMERO DE CUENTAS DE TAMAÑO 32-50  $\mu\text{m}$**
















5. VARIANDO EL NÚMERO DE CUENTAS DE TAMAÑO 50-86  $\mu\text{m}$
















**6. VARIANDO EL NÚMERO DE CUENTAS DE TAMAÑO 86-100 μm**
















### 7. VARIANDO EL NÚMERO DE CUENTAS DE TAMAÑO 100-1000 $\mu\text{m}$









## ANEXO IV

### Nomenclatura empleada y diagramas de pareto de los diseños experimentales realizados.

---

#### ÍNDICE

1.	Nomenclatura de los diseños experimentales .....	2
2.	Nomenclatura de los diagramas de pareto .....	2
3.	Diagramas de pareto del diseño factorial $2^{7-3}$ .....	3
4.	Diagramas de pareto del diseño factorial $2^7$ .....	7

## 1. NOMENCLATURA DE LOS DISEÑOS EXPERIMENTALES

Por las características del programa empleado para este estudio, ha sido necesario emplear una nomenclatura específica en los gráficos, que se detalla en las siguientes tablas:

Medida Lasentec (cps)	1-5 $\mu\text{m}$	5-10 $\mu\text{m}$	10-32 $\mu\text{m}$	32-50 $\mu\text{m}$	50-86 $\mu\text{m}$	86-100 $\mu\text{m}$	100-1000 $\mu\text{m}$
Nomenclatura	in1	in2	in3	in4	in5	in6	in7
Valor +1	637	1245	6072	4154	3515	839	3036
Valor -1	63	159	875	748	1051	324	1396

## 2. NOMENCLATURA DE LOS DIAGRAMAS DE PARETO


Por las características del programa empleado para este estudio, ha sido necesario emplear una nomenclatura específica en los gráficos, que se detalla en las siguientes tablas:

Nomenclatura Diagramas Pareto	A	B	C	D	E	F	G
Medida FBRM (cps)	32-50 $\mu\text{m}$	50-86 $\mu\text{m}$	10-32 $\mu\text{m}$	5-10 $\mu\text{m}$	86-100 $\mu\text{m}$	1-5 $\mu\text{m}$	100-1000 $\mu\text{m}$


Nomenclatura Diagramas Pareto	IC48h	Esp48h	IC7d	Esp7d	MF7d	Dens7d	DensT
Símbolo Estándar	$F_s$ 48h	Espesor 48h	$F_s$ 7d	Espesor 7d	$M$ 7d	Densidad 7d	Densidad Tierno

3. DIAGRAMAS DE PARETO DEL DISEÑO FACTORIAL 2<sup>7-3</sup>


Pareto Chart for IC48h




Pareto Chart for Esp48h




Pareto Chart for IC7d




Pareto Chart for Esp7d




### Pareto Chart for MF7d



### Pareto Chart for Dens7d




Pareto Chart for DensT




4. DIAGRAMAS DE PARETO DEL DISEÑO FACTORIAL 2<sup>7</sup>

Pareto Chart for IC48h







### Pareto Chart for IC7d




### Pareto Chart for Esp7d



### Pareto Chart for MF7d




### Pareto Chart for Dens 7d







### Pareto Chart for IC48h




### Pareto Chart for Esp48h




### Pareto Chart for IC7d




### Pareto Chart for Esp7d




### Pareto Chart for MF7d



### Pareto Chart for Dens7d



# Pareto Chart for DensT



## ANEXO V

**Gráficos del error de entrenamiento y de predicción frente al número de iteraciones para las redes creadas de 3 entradas y 6 salidas.**






---

### ÍNDICE






1. Resultados para redes neuronales de una capa oculta..... 2
2. Resultados para redes neuronales de dos capas ocultas..... 23

## 1. RESULTADOS PARA REDES NEURONALES DE UNA CAPA OCULTA






En cada figura se indican el número de neuronas y el momento para cada red creada (red “x” de 5).








Anexo V – Errores de entrenamiento y predicción frente al número de iteraciones



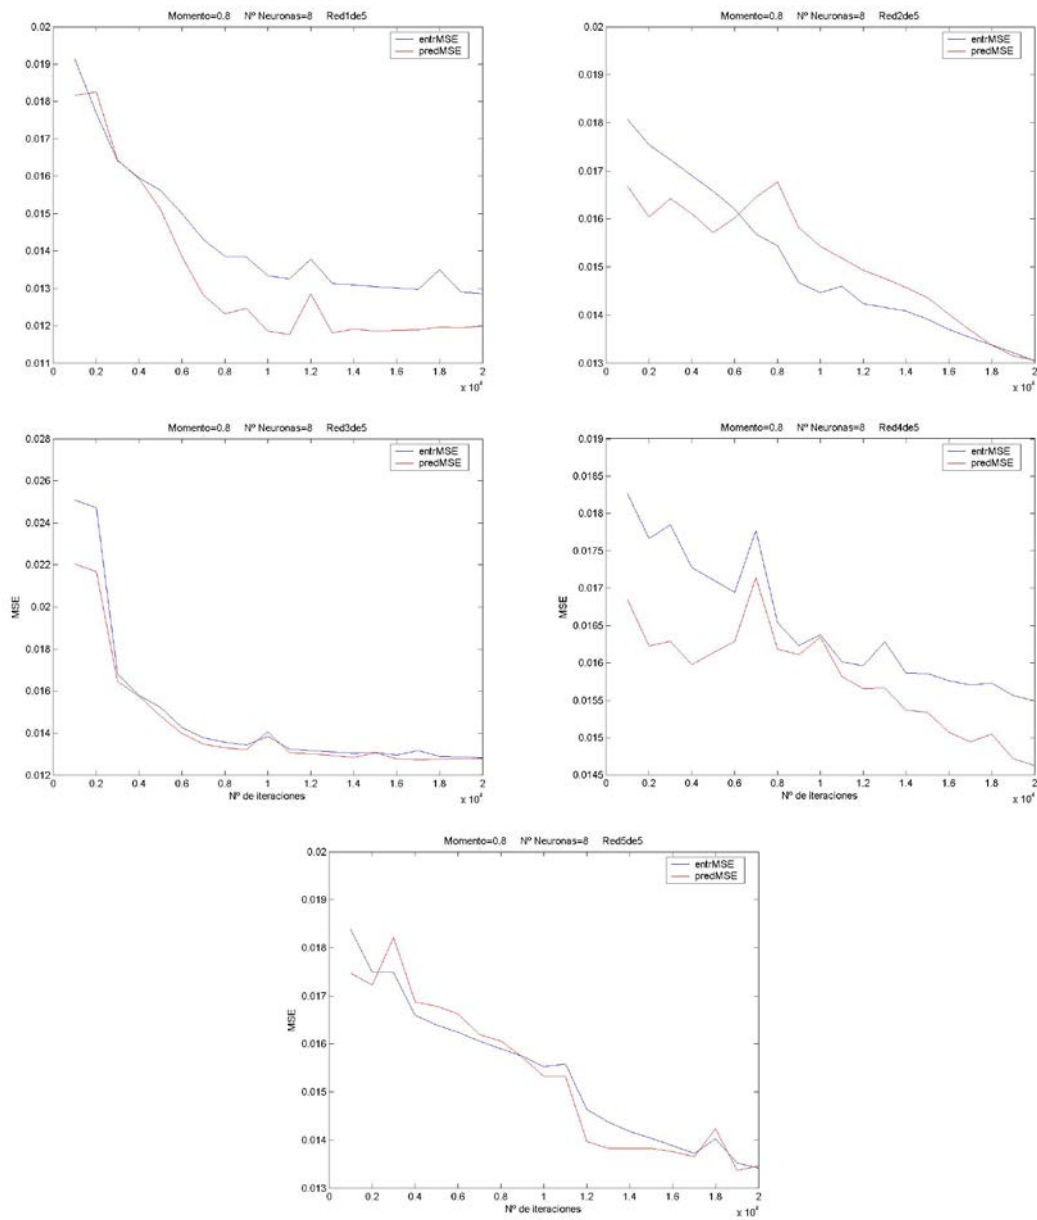
Anexo V – Errores de entrenamiento y predicción frente al número de iteraciones








Anexo V – Errores de entrenamiento y predicción frente al número de iteraciones








Anexo V – Errores de entrenamiento y predicción frente al número de iteraciones








# Anexo V – Errores de entrenamiento y predicción frente al número de iteraciones






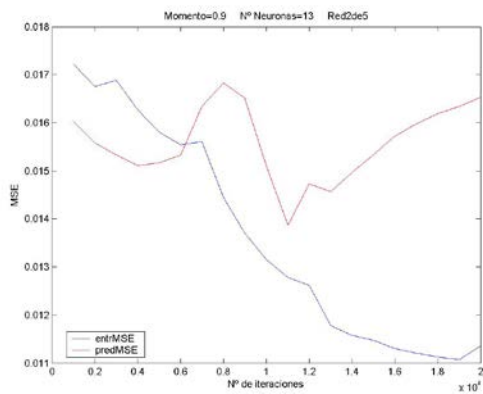

Anexo V – Errores de entrenamiento y predicción frente al número de iteraciones








Anexo V – Errores de entrenamiento y predicción frente al número de iteraciones








Anexo V – Errores de entrenamiento y predicción frente al número de iteraciones








Anexo V – Errores de entrenamiento y predicción frente al número de iteraciones








Anexo V – Errores de entrenamiento y predicción frente al número de iteraciones








Anexo V – Errores de entrenamiento y predicción frente al número de iteraciones








Anexo V – Errores de entrenamiento y predicción frente al número de iteraciones








Anexo V – Errores de entrenamiento y predicción frente al número de iteraciones








Anexo V – Errores de entrenamiento y predicción frente al número de iteraciones








# Anexo V – Errores de entrenamiento y predicción frente al número de iteraciones








Anexo V – Errores de entrenamiento y predicción frente al número de iteraciones








# Anexo V – Errores de entrenamiento y predicción frente al número de iteraciones








# Anexo V – Errores de entrenamiento y predicción frente al número de iteraciones








Anexo V – Errores de entrenamiento y predicción frente al número de iteraciones








Anexo V – Errores de entrenamiento y predicción frente al número de iteraciones








## 2. RESULTADOS PARA REDES NEURONALES DE DOS CAPAS OCULTAS








Anexo V – Errores de entrenamiento y predicción frente al número de iteraciones








## Anexo V – Errores de entrenamiento y predicción frente al número de iteraciones








## Anexo V – Errores de entrenamiento y predicción frente al número de iteraciones








## Anexo V – Errores de entrenamiento y predicción frente al número de iteraciones








## Anexo V – Errores de entrenamiento y predicción frente al número de iteraciones








Anexo V – Errores de entrenamiento y predicción frente al número de iteraciones








Anexo V – Errores de entrenamiento y predicción frente al número de iteraciones








Anexo V – Errores de entrenamiento y predicción frente al número de iteraciones








Anexo V – Errores de entrenamiento y predicción frente al número de iteraciones



Anexo V – Errores de entrenamiento y predicción frente al número de iteraciones



Anexo V – Errores de entrenamiento y predicción frente al número de iteraciones



## ANEXO VI

**Gráficos tridimensionales que muestran el efecto de la variación de cada entrada a la red sobre sus salidas.**


---

### ÍNDICE


1. Efecto de las variables de entrada en las propiedades finales ..... 2

### 1. EFECTO DE LAS VARIABLES DE ENTRADA EN LAS PROPIEDADES FINALES


Este efecto se evalúa analizando las gráficas tridimensionales obtenidas. Se utiliza una notación diferente para las variables estudiadas, siendo *I.C.* el  $F_s$ ; *M.F.* el  $M$ , y *#/seg* las *cps*.




Dens. Tno. = 1.80




Dens. Tno. = 1.82




Dens. Tno. = 1.84




Dens. Tno. = 1.87




Dens. Tno. = 1.89




Dens. Tno. = 1.91




Dens. Tno. = 1.94




Dens. Tno. = 1.96




Dens. Tno. = 1.98




Dens. Tno. = 1.80




Dens. Tno. = 1.82




Dens. Tno. = 1.84




Dens. Tno. = 1.87




Dens. Tno. = 1.89




Dens. Tno. = 1.91




Dens. Tno. = 1.94




Dens. Tno. = 1.96




Dens. Tno. = 1.98




Dens. Tno. = 1.80




Dens. Tno. = 1.82




Dens. Tno. = 1.84




Dens. Tno. = 1.87




Dens. Tno. = 1.89




Dens. Tno. = 1.91




Dens. Tno. = 1.94




Dens. Tno. = 1.96




Dens. Tno. = 1.98




Dens. Tno. = 1.80




Dens. Tno. = 1.82




Dens. Tno. = 1.84




Dens. Tno. = 1.87




Dens. Tno. = 1.89




Dens. Tno. = 1.91




Dens. Tno. = 1.94




Dens. Tno. = 1.96




Dens. Tno. = 1.98




Dens. Tno. = 1.80




Dens. Tno. = 1.82




Dens. Tno. = 1.84




Dens. Tno. = 1.87




Dens. Tno. = 1.89




Dens. Tno. = 1.91




Dens. Tno. = 1.94




Dens. Tno. = 1.96




Dens. Tno. = 1.98




Dens. Tno. = 1.80




Dens. Tno. = 1.82




Dens. Tno. = 1.84




Dens. Tno. = 1.87




Dens. Tno. = 1.89




Dens. Tno. = 1.91



Dens. Tno. = 1.94



Dens. Tno. = 1.96



Dens. Tno. = 1.98

## **ANEXO VII**

### **Programas informáticos desarrollados.**

---

### **ÍNDICE**

1.	Programas informáticos .....	2
1.1.	Programa “optimizador_red_3_6.m” .....	2
1.2.	Subrutina “crearedesylasguarda.m” .....	3
1.3.	Subrutina “creador_red.m” .....	4
1.4.	Subrutina “resultados_red_3_6.m” .....	4
1.5.	Programa “test_resultados_red_3_6.m” .....	9

## 1. PROGRAMAS INFORMÁTICOS

Se han desarrollado programas y subrutinas en Matlab V6.5 R13, las cuales se exponen a continuación.

### 1.1. PROGRAMA “OPTIMIZADOR\_RED\_3\_6.M”.

Este programa crea todos los gráficos de representación del error de entrenamiento y de predicción frente al número de iteraciones, que se muestran en los resultados para la presente red. Emplea dos subrutinas: “crearedesy lasguarda.m”, y “creador\_red.m”. Sus funciones se verán más adelante.

```
clear all

RealInputs=[ Confidencial ]; %Datos de entrada.

RealOutputs=[ Confidencial ]; %Salidas medidas en planta.

LearnInputs=[ Confidencial ]; %Entradas seleccionadas para comprobación del error.

LearnOutputs=[ Confidencial ]; %Salidas seleccionadas para comprobación del error.

momento=[0.7,0.8,0.9];
NNeuronas=[3,8,13,18,23,28];
Numredes=5;
h=20; %Numero de pasos.
IteraMax=20000;

strNumredes=num2str(Numredes);

[pn,minp,maxp,tn,mint,maxt] = premmmx(RealInputs,RealOutputs);
P=pn.*0.4+0.5;
T=tn.*0.4+0.5;
p2n=trammmx(LearnInputs,minp,maxp);
P2=p2n.*0.4+0.5;
t2n=trammmx(LearnOutputs,mint,maxt);
T2=t2n.*0.4+0.5;

for n=1:size(NNeuronas,2)
    strNNeuronas=num2str(NNeuronas(n));

    [pn,minp,maxp,tn,mint,maxt,P,T]=crearedesy lasguarda(NNeuronas(n),RealInputs,RealOutputs,Numredes);
    % Activada cuando se crean nuevas redes. Desactivada para trabajar con redes
    % ya creadas

    for m=1:size(momento,2)
        strmomento=num2str(momento(m));
```

```

for i=1:Numredes
    stri=num2str(i);
    strNumredes=num2str(Numredes);
    fileload=strcat('red_con_',strNNeuronas,'neur_',stri,'de',strNumredes,'.mat');
    load(fileload);

    for j=1:h
        net.trainParam.epochs=(IteraMax/h)*j;
        net.trainParam.show=net.trainParam.epochs/1;
        net.trainParam.lr=0.05;
        net.trainParam.lr_inc=1.05;
        net.trainParam.lr_dec=0.7;
        net.trainParam.mc=momento(m);
        %net.trainParam.goal=0.0001;

        [trainednet,tr]=train(net,P,T); %Las funciones de entrenamiento y de aprendizaje, asi
como los
        % parametros a visualizar se concretan en el fichero creador_red.m

        [Y,Pf,Af,E,simPERF]=sim(trainednet,P2,[],[],T2);
        netPERF(j)=tr.perf(1,size(tr.perf,2));
        simMSE(j)=simPERF;
        itera(j)=net.trainParam.epochs;
    end
    hold off
    figure((Numredes*(size(momento,2)))*(n-1)+Numredes*(m-1)+i)
    plot(itera,netPERF,'b-',itera,simMSE,'r-')
    titulo=strcat('Momento=',strmomento,' N° Neuronas=',strNNeuronas,'
Red',stri,'de',strNumredes);
    title(titulo)
    xlabel('N° de iteraciones')
    ylabel('MSE')
    legend('entrMSE','predMSE',0)
    Numfig=(Numredes*(size(momento,2)))*(n-1)+Numredes*(m-1)+i;
    pause(5)

saveas(Numfig,strcat('mom',strmomento,'_neur',strNNeuronas,'_',stri,'de',strNumredes,'.jpg'))
end
end
end
end

```

## 1.2. SUBROUTINA “CREAREDESYLASGUARDA.M”.

Empleada dentro del anterior programa, esta subrutina se encarga de crear el número indicado de redes y guardarlas en archivos de Matlab para su posterior empleo. Su código es el siguiente:

```

function
[pn,minp,maxp,tn,mint,maxt,P,T]=crearedesylassguarda(NNeuronas,RealInputs,RealOutputs,Numr
edes)

```

```

for i=1:Numredes
    [pn,minp,maxp,tn,mint,maxt,P,T,net] =
creador_red(NNeuronas,RealInputs,RealOutputs,Numredes);
    stri=num2str(i);
    strNumredes=num2str(Numredes);
    strNNeuronas=num2str(NNeuronas);
    filetosave=strcat('red_con_',strNNeuronas,'neur_',stri,'de',strNumredes);
    save(filetosave,'net');
end

```

### 1.3. SUBROUTINA “CREADOR\_RED.M”.

En esta subrutina se crea la red con las características deseadas. Esta es la subrutina a variar si se desean redes con dos capas ocultas, por ejemplo.

```

function [pn,minp,maxp,tn,mint,maxt,P,T,net] =
creador_red(NNeuronas,RealInputs,RealOutputs,Numredes)
% CREADOR_RED crea una red neuronal tipo backpropagation con una capa intermedia
% y la guarda en un fichero.
% Detailed explanation goes here

[pn,minp,maxp,tn,mint,maxt] = premmx(RealInputs,RealOutputs);
P=pn.*0.4+0.5;
T=tn.*0.4+0.5;
net=newff(minmax(P), [size(P,1),NNeuronas,size(T,1)], {'logsig','logsig','logsig'},
'traingdx','learngdm','mse');

```

### 1.4. SUBROUTINA “RESULTADOS\_RED\_3\_6.M”

Se empleará un programa en Matlab, para simular la red con los datos de validación, y para simular la red creando una estructura de datos de entrada tal que permita su visualización en gráficos tridimensionales de superficie donde se represente la respuesta de la red frente a dos de las variables de entrada, en el intervalo entre su mínimo y su máximo.

El programa, que es un archivo “function”, se expone a continuación.

```

function
[M,X,Y]=resultados_red_3_6(Med,INTMINX,INTMAXX,INTMINY,INTMAXY,DATOVAR,N
VAR)

% Este programa ejecuta gráficos donde se estudia el efecto de la
% variación de dos variables sobre cada una de las propiedades de salida.
%
% La orden a ejecutar es la siguiente:
%
%
[M,X,Y]=anal_dis_exp(Med,INTMINX,INTMAXX,INTMINY,INTMAXY,DATOVAR,NVAR)
%

```

```

% Donde:
%
% M: Matriz de respuestas de la red en el intervalo estudiado.
% X: Valores del eje X para la representación.
% Y: Valores del eje Y para la representación.
%      La ecuación de codificación empleada es: Cod=Real*m+b. m y b son calculados
haciendo coincidir
%      al máximo de los datos analizados con el valor codificado de 0.9 y al mínimo con el
valor 0.1
% Med: Vector fila de los valores constantes para las entradas a la red neuronal.
%      INTMINX,INTMAXX,INTMINY,INTMAXY: Intervalos a representar en ejes X e Y.
Valores mínimos y máximos de cada uno.
% DATOVAR: Vector fila con el numero de las entradas a variar (entre 1 y numero de entradas)
% NVAR: Numero de pasos en el mallado a representar entre el mínimo y el máximo de X e Y.
%
% Programa creado por: Álvaro Alonso Zorita (c)
% Versión 2 (Ene-2003)

% Lectura de la red neuronal optimizada.

RealInputs=[ Datos no mostrados ]; %Datos de entrada.

RealOutputs=[ Datos no mostrados ]; %Salidas medidas en planta.

LearnInputs=[ Datos no mostrados ]; %Entradas seleccionadas para comprobación del error.

LearnOutputs=[ Datos no mostrados ]; %Salidas seleccionadas para comprobación del error.

% Inserción de parámetros óptimos de red.

momento=[0.7];
NCapas=1; % Valores empleados: 1 y 2.
NNeuronas=[28];
Numred=1;
h=1; %Numero de pasos.
IteraMax=7000;

% Creación de cadenas de caracteres para nombrar archivos y variables.

strNumred=num2str(Numred);
strNNeuronas=num2str(NNeuronas(1));
strmomento=num2str(momento(1));

% Carga de la red optima según el numero de capas.

if NCapas==1
    filetoload=strcat('red_con_',strNNeuronas,'neur_',strNumred,'de5.mat');
elseif NCapas==2
    filetoload=strcat('red2c_con_',strNNeuronas,'neur_porcapa_',strNumred,'de5.mat');
end
load(filetoload);

% Tratamiento de los datos.

```

```

[pn,minp,maxp,tn,mint,maxt] = premmx(RealInputs,RealOutputs);
P=pn.*0.4+0.5;
T=tn.*0.4+0.5;
p2n=trammx(LearnInputs,minp,maxp);
P2=p2n.*0.4+0.5;
t2n=trammx(LearnOutputs,mint,maxt);
T2=t2n.*0.4+0.5;

% Definición de parámetros de entrenamiento de red.

net.trainParam.epochs=(IteraMax/h);
net.trainParam.show=net.trainParam.epochs/1;
net.trainParam.lr=0.05;
net.trainParam.lr_inc=1.05;
net.trainParam.lr_dec=0.7;
net.trainParam.mc=momento(1);
%net.trainParam.goal=0.0001;

% Entrenamiento de la red o carga de la red optima.

% [trainednet,tr]=train(net,P,T);
% save('REDOPTIMA','trainednet')
% Se activan las dos líneas anteriores si se ejecuta el programa por primera
% vez.

load('REDOPTIMA.mat')
% Activado cuando ya se ha guardado la red optima.

[YY,Pf,Af,E,simPERF]=sim(trainednet,P2,[],[],T2);
simMSE=simPERF % Visualización del error cometido en la predicción.

% Operaciones previas a la representación de datos.

NPROP=size(mint,1);
PROP=1:NPROP;
NINPUT=size(minp,1);
SQNVAR=NVAR^2;

% Se crea la matriz con cada punto a evaluar por la red (cada nodo del mallado).

for i=1:NINPUT
    for j=1:SQNVAR
        PP(i,j)=Med(i);
    end
end

% Se modifican las filas con las entradas a variar.

for n=1:NVAR
    for m=1:NVAR
        nm(1,m)=NVAR*(n-1)+m;
    end
    PP(DATOVAR(1,1),nm)=INTMINX:(INTMAXX-INTMINX)/(NVAR-1):INTMAXX;
end

```

```

for n=1:NVAR
    for m=1:NVAR
        nm(1,m)=NVAR*m-(NVAR-n);
    end
    PP(DATOVAR(1,2),nm)=INTMINY:(INTMAXY-INTMINY)/(NVAR-1):INTMAXY;
end

```

% Se utiliza la red para obtener la matriz de resultados TT.

```

[TTCOD2]=sim(trainednet,PP);
TTCOD=(TTCOD2-0.5)/0.4;
TT=postmnmx(TTCOD,mint,maxt);

```

% Se definen los ejes X e Y de las representaciones y se descodifican sus valores.

```

X=INTMINX:(INTMAXX-INTMINX)/(NVAR-1):INTMAXX;
X=(maxp(DATOVAR(1,1),1).*(INTMAXX-INTMINX)./(maxp(DATOVAR(1,1),1)-
minp(DATOVAR(1,1),1))+X-INTMAXX)./((INTMAXX-
INTMINX)./(maxp(DATOVAR(1,1),1)-minp(DATOVAR(1,1),1))));
Y=INTMINY:(INTMAXY-INTMINY)/(NVAR-1):INTMAXY;
Y=(maxp(DATOVAR(1,2),1).*(INTMAXY-INTMINY)./(maxp(DATOVAR(1,2),1)-
minp(DATOVAR(1,2),1))+Y-INTMAXY)./((INTMAXY-
INTMINY)./(maxp(DATOVAR(1,2),1)-minp(DATOVAR(1,2),1))));

```

% Se reordenan los resultados para su representación grafica.

```

T2COD=(T2-0.5)/0.4;
T2REP=postmnmx(T2COD,mint,maxt);
YCOD=(YY-0.5)/0.4;
YREP=postmnmx(YCOD,mint,maxt);

```

```

for i=1:NPROP
    for n=1:NVAR
        for m=1:NVAR
            nm(1,m)=NVAR*(n-1)+m;
        end
        M(n,:)=TT(PROP(1,i),nm);
    end

```

figure(i+NPROP)

[m,b,r] = postreg(T2REP(i,:),YREP(i,:));

% Se activa la figura i para cada paso del bucle.

figure(i)

% Se procede a la representación. Se activa aquella que interesa.

```

surfc(X,Y,M)
%contour(X,Y,M)

```

% Se definen los títulos de cada coordenada.

```

        if DATOVAR(1,1)==1
        xlabel('Densidad Tierno')
        elseif DATOVAR(1,1)==2
        xlabel('#/seg 10-32 micras')
        elseif DATOVAR(1,1)==3
        xlabel('#/seg 1-1000 micras')
        end
        if DATOVAR(1,2)==1
        ylabel('Densidad Tierno')
        elseif DATOVAR(1,2)==2
        ylabel('#/seg 10-32 micras')
        elseif DATOVAR(1,2)==3
        ylabel('#/seg 1-1000 micras')
        end
        if i==1
        zlabel('I.C. 48 horas')
        pause(2)
        saveas(i,'IC48h.jpg')
        elseif i==2
        zlabel('Espesor 48 horas')
        pause(2)
        saveas(i,'Esp48h.jpg')
    elseif i==3
        zlabel('I.C. 7 dias')
        pause(2)
        saveas(i,'IC7d.jpg')
    elseif i==4
        zlabel('Espesor 7 dias')
        pause(2)
        saveas(i,'Esp7d.jpg')
    elseif i==5
        zlabel('M.F. 7 dias')
        pause(2)
        saveas(i,'MF7d.jpg')
    elseif i==6
        zlabel('Densidad 7 dias')
        pause(2)
        saveas(i,'Dens7d.jpg')
        end
end

% Esta parte se emplea para guardar los resultados en archivos ASCII.
% Solo se activa si es conveniente quitando los símbolos "%".

% se cambia el nombre de los
% archivos para no sobrescribirlos.
% dlmwrite ('Salidasim.asc',YY,' ')
% dlmwrite ('Salidareal.asc',LearnOutputs,' ')

```

### 1.5. PROGRAMA “TEST\_RESULTADOS\_RED\_3\_6.M”

Para ejecutar este programa se recurre al archivo “script” que se muestra a continuación.

```
% Inicializacion del sistema.

clear all
hold off

Med=[0.800    0.500    0.500]; % Valores optimos para cada uno de los parametros de
entrada.

% Se define el numero de pasos en el mallado a representar,
%y los intervalos de valores.

INTMINX=0.1;
INTMAXX=0.9;
INTMINY=0.1;
INTMAXY=0.9;
NVAR=90;

% Parametros de entrada que se varian [X Y].

DATOVAR=[2 3]; % Varía entre 1 y 3

[M X
Y]=resultados_red_3_6(Med,INTMINX,INTMAXX,INTMINY,INTMAXY,DATOVAR,NVAR);
```

Con estos programas se obtienen todas las representaciones y tablas que permitirán analizar la red neuronal óptima de 3 entradas y 6 salidas.