

MODELADO VISUAL DE PROCESOS INDUSTRIALES

Ignacio Díaz Blanco, Abel A. Cuadrado Vega
Alberto B. Diez González, Guillermo Ojea Merín

*Area de Ingeniería de Sistemas y Automática
Departamento de Ingeniería Eléctrica, Electrónica de
Computadores y Sistemas
Universidad de Oviedo
{idiaz,cuadrado,alberto,gojea}@isa.uniovi.es*

Resumen: En este artículo se describe una metodología basada en técnicas de reducción de la dimensión que permite la representación concurrente de distintos tipos de conocimiento relativos a procesos continuos multivariados, tales como reglas, modelos físicos, correlaciones o casos, en una visualización única –*mapa del proceso*–. La visualización simultánea de todos estos tipos de conocimiento permite contrastarlos entre sí, validar hipótesis y descubrir modelos nuevos del proceso, lo que hace posible explotar de forma eficiente el conocimiento disponible así como descubrir conocimiento nuevo acerca del proceso, constituyendo lo que podría denominarse *modelado visual de procesos*. El procedimiento aquí descrito permite además monitorizar en línea el estado del proceso de forma consistente con las representaciones anteriores, lo que facilita la identificación del mismo con estados o condiciones conocidas.

Copyright ©2005 CEA-IFAC

Palabras clave: Supervisión de procesos, minería de datos visual, reducción de la dimensión, mapa topológico autoorganizado (SOM).

1. INTRODUCCIÓN.

Muchos procesos industriales son de naturaleza compleja, tratándose a menudo de sistemas de gran dimensión, con dinámicas no lineales e interacciones entre sus partes de las que emergen comportamientos difícilmente predecibles. Con frecuencia resulta imposible o inviable construir un modelo axiomático que permita explicar el comportamiento del proceso a partir de las leyes de la Física, bien por el mero desconocimiento o conocimiento parcial de las leyes que rigen dicho proceso, bien por la dificultad que supone crear dicho modelo, o bien por tratarse de un proceso variante en el tiempo.

El abaratamiento de las tecnologías para la captura y almacenamiento de datos que ha tenido

lugar en la última década ha hecho que en muchos de estos procesos se disponga de grandes cantidades de datos, provenientes de diferentes sensores orientados a proporcionar información relativa a la condición o estado de funcionamiento de los mismos, pero que en ocasiones es completamente desaprovechada. En la mayor parte de los casos, el problema no está en si la información acerca del proceso está o no presente sino, más específicamente, en cómo ésta puede ser presentada de una forma útil y manejable.

1.1 *Formulación del problema.*

En el caso de muchos procesos industriales, un escenario típico al que se enfrenta el ingeniero de producción o mantenimiento es el de un proceso

dotado de varias decenas de sensores ubicados en puntos estratégicos del mismo, cuyos datos han sido sistemáticamente almacenados durante años en enormes bases de datos en las que la información sobre el proceso permanece infrutilizada junto con, posiblemente, algunos modelos –ecuaciones físicas o reglas empíricas– que describen dicho proceso o partes del mismo de forma a veces incompleta o insatisfactoria. Se trata, por tanto, de una situación en la que el conocimiento acerca del proceso se halla disperso, expresado de forma heterogénea, en forma de datos y modelos de distintos tipos. Algunos de los tipos de conocimiento habituales con los que cuenta el ingeniero de proceso son los siguientes:

- *Datos de proceso:* En general suele disponerse de una matriz de datos en la que cada vector recoge d valores, correspondientes a lecturas en los sensores o a parámetros descriptivos obtenidos mediante técnicas de extracción de características.
- *Casos previos:* A menudo es posible vincular grupos de datos concretos con el conocimiento disponible acerca de una incidencia o *caso* ocurridos anteriormente y recogida en un diario o parte de incidencias (hoy en día almacenados como metadatos en soporte informático), en los que se anotan diversos datos del proceso –fecha, hora, estado de producción– junto con un diagnóstico de lo sucedido y los procedimientos adoptados para su solución.
- *Modelos físicos:* Parte del conocimiento del proceso puede estar disponible a través de modelos físico-matemáticos que describen las interrelaciones entre las distintas variables del proceso como, por ejemplo, relaciones funcionales entre éstas o ecuaciones diferenciales (modelos dinámicos). En procesos complicados, sin embargo, estos modelos suelen ser poco precisos o describir sólo partes del mismo.
- *Reglas:* Otra forma de conocimiento, muy común entre operarios y tecnólogos del proceso, viene dada en forma de reglas del tipo:

Si x_i es muy alta Y x_j es baja Y
 ... ENTONCES ...

Este tipo de reglas son, de hecho, modelos, en la medida en que permiten describir de forma compacta y manejable una realidad compleja como puede ser un proceso industrial.

- *Correlaciones:* Otra forma de conocimiento son las dependencias o correlaciones entre dos o más variables del proceso así como el signo de las mismas. Asimismo, el patrón de correlaciones entre las variables puede variar en función del estado o modo de funcionamiento del proceso y, por tanto, aportar información sobre el mismo.

En este escenario, el problema a resolver, puede plantearse, por tanto, en los siguientes términos:

A partir de las distintas fuentes de conocimiento disponibles sobre el proceso, las cuales ofrecen “vistas parciales” del mismo, definir métodos para integrarlas en una representación unificada que permita razonar visualmente y enlazar la información y los conceptos e ideas sobre el proceso que aportan cada una de ellas. A partir de esta idea, desarrollar metodologías que faciliten:

- a) *La comprensión y el entendimiento del proceso, que permitan mejorar el funcionamiento del mismo y la calidad del producto final.*
- b) *La monitorización de la condición o estado de funcionamiento del proceso con el objeto de corregir desviaciones o detectar anomalías.*

Se trata, en definitiva, de obtener un *modelo visual* de comportamiento del sistema a partir de los datos y del conocimiento previo disponible sobre el proceso, que permita explotar este conocimiento así como descubrir conocimiento nuevo para la supervisión y mejora del proceso.

El resto del artículo está estructurado como sigue. En la sección 2 se presenta el enfoque de la visualización de información y su relación con el modelado (visual) de procesos industriales. En la sección 3 se describe el principio de reducción de la dimensión junto con un cuerpo de técnicas de visualización del conocimiento basadas en dicho principio, orientadas al modelado visual de procesos. En la sección 4 se presentan algunas aplicaciones industriales de estas ideas y, finalmente, la sección 5 concluye el trabajo.

2. MODELADO VISUAL DE PROCESOS

2.1 El enfoque de la visualización

El problema formulado en la sección anterior reúne ingredientes propios de la Minería de Datos y en particular de lo que recientemente se ha venido a denominar *Visual Data Mining* (Minería de Datos Visual) (Wong, 1999). En el caso particular de la supervisión de procesos, el objetivo según este enfoque consiste en la búsqueda de representaciones visuales que permitan describir el proceso, explicarlo y predecir su comportamiento. Una representación visual que cumpla estas funciones puede considerarse, en definitiva, un *modelo visual del proceso*.

Uno de los enfoques empleados en la Minería de Datos Visual es el de la *reducción de la dimensión*. La idea consiste en generar un mapeo o proyección de los datos multidimensionales sobre un espacio de baja dimensionalidad (2D ó 3D) en el que éstos pueden ser visualizados, preservando al mismo

tiempo las principales propiedades geométricas o estadísticas de los datos originales. La potencia de esta idea estriba en la posibilidad de “traducir” al lenguaje visual (imágenes) los datos y tipos de conocimiento descritos anteriormente, permitiendo operar y razonar con ellos de forma visual. La idea se describe en la figura 1.

Las técnicas de visualización de datos han sido objeto de considerable atención en los últimos años para el análisis de grandes volúmenes de datos multidimensionales. Entender algo a menudo es llamado “verlo”. Tratamos de “aclarar” ideas y con frecuencia “enfocamos” los problemas (Card *et al.*, 1999). El ser humano razona a menudo con metáforas visuales para describir procesos cognitivos y más del 40% del cerebro está dedicado a tareas visuales. Aunque la idea de utilizar la reducción de la dimensión para la visualización de datos no es nueva (Hotelling, 1933; Torgerson, 1958; Sammon, 1969; Friedman, 1987), el avance en la potencia de computación y las técnicas de visualización han potenciado enormemente esta línea en los últimos años (Keim, 2001).

Recientemente, dos artículos publicados de forma independiente en *Science*, por Tenenbaum (Tenenbaum *et al.*, 2000) y Roweis (Roweis and Saul, 2000) describen cómo ciertos métodos de reducción de la dimensión evocan sorprendentemente la forma en la que el ser humano asimila ciertos tipos de información compleja (imágenes visuales en distintas posiciones). Procesos aparentemente muy complejos pueden ser descritos a menudo con unas pocas variables y un modelo no lineal que vincula el espacio multidimensional de los datos del proceso con un espacio de baja dimensión (por ejemplo 2D ó 3D) en el que tanto el modelo del proceso como la evolución de su estado pueden ser literalmente “visualizados”.

2.2 Visualización de procesos

Más específicamente, en el campo de la monitorización y visualización de procesos industriales complejos, muchos autores adoptan el enfoque de reducción de la dimensión para la monitorización de la condición. En (Wilson and Irwin, 1999), los autores utilizan un mapa sobre un espacio de baja dimensión generado mediante redes de funciones base radiales (RBF) que permite describir los estados de un proceso químico (columna de destilación) en términos de las regiones de sus dos componentes principales no lineales, así como detectar fallos en sensores a través de los residuos del modelo generado.

En (Kohonen *et al.*, 1996), Kohonen describe el uso del *Self Organizing Map* (SOM) para la monitorización de la condición de un transformador eléctrico mediante la proyección del estado

del proceso sobre un plano en el que pueden ser representados los “mapas” de las distintas variables del mismo –corriente de carga, temperatura en los devanados y en el aceite, contenido en hidrógeno, etc.– que literalmente “dibujan” los posibles estados del proceso. Esta idea ha sido aplicada por autores del grupo de Kohonen en la supervisión de procesos industriales (Alhoniemi *et al.*, 1999) y sistemas de telecomunicaciones (Raivio *et al.*, 2001), entre otras.

En una línea muy similar, Bishop propone el *Generative Topographic Mapping* (GTM), (Bishop *et al.*, 1998), una reformulación probabilística del SOM pero de carácter continuo que aproxima el espacio de los datos mediante un espacio latente, de baja dimensión. Los autores han aplicado su modelo en el diagnóstico del flujo de fluido multifase en oleoductos.

En (Díaz, 2000) se describe el uso del SOM para la monitorización de la condición de procesos industriales complejos con aplicación a procesos reales (un motor asíncrono de baja potencia y un motor CC de 6000 kW instalado en un tren acabador de laminación de la empresa Aceralia), introduciendo algunas técnicas novedosas en este campo como el uso de una versión interpolada de SOM para la representación de trayectorias de estado continuas, los mapas de activación para la representación de casos y la visualización de residuos vectoriales.

Ya en el campo del modelado visual de procesos, los autores presentan en (Díaz *et al.*, 2002) los *mapas de reglas* y los *mapas de modelos*, que permiten incorporar conocimiento *a priori* expresado en términos de reglas (nítidas o difusas) y modelos físicos a la visualización SOM, representándolas en términos de regiones en el mapa del proceso. Recientemente, se han propuesto los *mapas de correlaciones locales* (Díaz *et al.*, 2002) que permiten explorar de forma visual, sobre el mapa del proceso, las correlaciones entre las variables del proceso para los distintos estados de funcionamiento. Las ideas anteriores han tenido aplicación principalmente en supervisión y minería de datos visual de procesos de la industria del acero (Cuadrado *et al.*, 2002; Díaz *et al.*, 2003).

3. TÉCNICAS DE VISUALIZACIÓN DE PROCESOS BASADAS EN SOM

3.1 Reducción de la Dimensión basada en SOM.

El SOM consiste en una colección de elementos, llamados *unidades*, *neuronas* o *nodos*, enlazados entre sí mediante conexiones laterales, formando una retícula o “sábana”. Cada unidad i lleva aparejadas unas coordenadas \mathbf{m}_i en el *espacio de datos* del proceso, D , típicamente del orden de

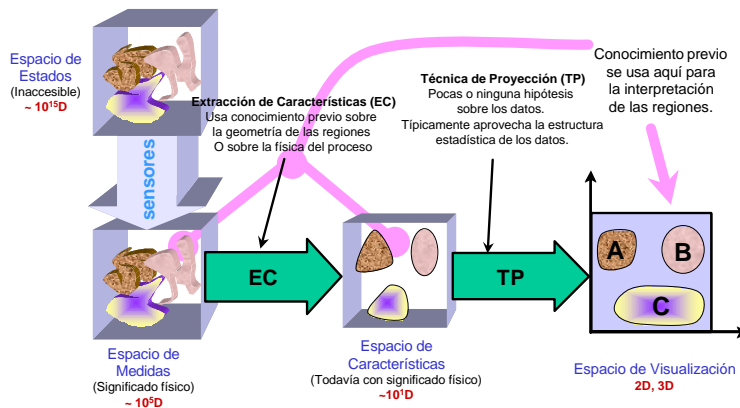
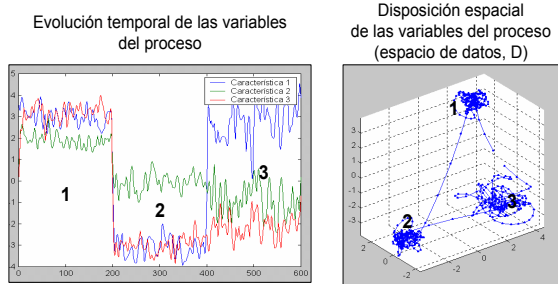
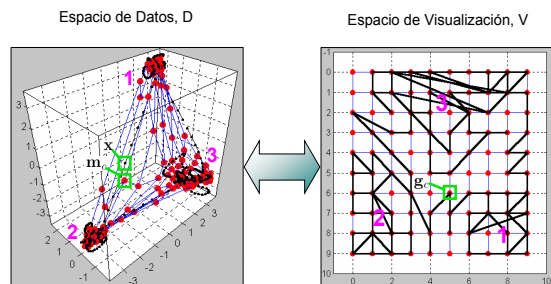


Figura 1. Etapas de reducción de la dimensión típicas en el modelado visual de procesos.



(a) Datos del proceso. Representación temporal y representación en el espacio de datos.



(b) Aproximación de los datos del proceso mediante SOM, y proyección de una trayectoria $\mathbf{x}(t)$ definida en el espacio de datos sobre el espacio de visualización.

Figura 2. Reducción de la Dimensión basada en SOM.

una o varias decenas de dimensiones, formado por medidas o características descriptivas del estado del proceso, y unas coordenadas \mathbf{g}_i en un espacio típicamente bidimensional¹, denominado *espacio de visualización*, V , en el cual está definida la retícula.

Resulta posible, entonces, establecer una correspondencia o *mapeo* entre puntos representativos de la geometría de los datos del proceso en D , y

¹ Existen otros tipos de topologías tales como mallas 3D, mallas hipercúbicas, toroidales, en forma de árbol (cfr. (Kohonen, 1995)), aunque –salvo en las 3D, que darían lugar a cajas en lugar de planos– no resultan prácticas para la visualización.

la retícula ordenada de puntos en el espacio de visualización de dimensión 2D ó 3D

$$\mathbf{m}_i \leftrightarrow \mathbf{g}_i$$

De acuerdo con esta correspondencia, se puede definir de forma muy sencilla un mapeo funcional $\mathcal{S} : \mathbb{R}^n \rightarrow \mathbb{R}^2$ del espacio de datos sobre el espacio de visualización de la siguiente manera:

$$c = \arg \min_i \{ \|\mathbf{x} - \mathbf{m}_i\| \}$$

$$\mathbf{x} \rightarrow \mathcal{S}(\mathbf{x}) = \mathbf{g}_c \tag{1}$$

es decir, a cada vector de características \mathbf{x} del proceso, se le asigna la posición \mathbf{g}_c en la retícula 2D que se corresponde con el prototipo \mathbf{m}_c que mejor define o aproxima a \mathbf{x} en el espacio de datos del proceso. Aplicando la expresión (1) a cada punto de una trayectoria $\mathbf{x}(t)$ se induce una trayectoria $\mathcal{S}(\mathbf{x}(t))$ que puede visualizarse en V . Esto permite la representación visual en línea de la evolución del estado de un proceso tal y como se muestra en la figura 2.

No obstante, para que esta proyección sea apta para la visualización debe reunir dos requisitos:

- a) Constituir una buena aproximación de los datos del espacio de datos, D .
- b) El mapeo tiene que ser suave y ordenado, a saber, puntos vecinos en V según la topología definida deben corresponderse con puntos próximos en D .

Kohonen propone a principios de los ochenta un algoritmo de carácter competitivo-cooperativo (Kohonen, 1995) que adapta las coordenadas \mathbf{m}_i de las neuronas en el espacio de datos, disponiéndolas en dicho espacio de forma que se ajusten a la geometría de los datos del proceso \mathbf{x}_k en D , preservando a la vez la topología definida por la retícula, en el sentido de que neuronas con coordenadas próximas en la retícula –neuronas *vecinas*– ocupen posiciones próximas en el espacio de los datos (ver figura 2).

El algoritmo del SOM, propuesto por Kohonen (Kohonen, 1995) es el siguiente:

$$\forall \mathbf{m}_i, \forall \mathbf{x}_k \in D \subset \mathbb{R}^n$$

$$c = \arg \min_i \|\mathbf{x}_k - \mathbf{m}_i(t)\|$$

$$\mathbf{m}_i(t+1) = \mathbf{m}_i(t) + \alpha(t)h_{ci}(t)[\mathbf{x}_k - \mathbf{m}_i(t)]$$

en el que el núcleo h_{ci} es, en general, una función decreciente con la distancia entre las neuronas c e i definida por la topología de la retícula² y el factor de aprendizaje $\alpha(t)$ suele hacerse decrecer lentamente según evoluciona el entrenamiento.

3.2 Cartografiado del mapa

El algoritmo SOM descrito anteriormente, análogamente a otras técnicas de proyección como PCA, GTM, o las proyecciones MDS (*multidimensional scaling*), permite definir un *mapa* del proceso que puede visualizarse en un gráfico. Cada una de las regiones de ese mapa describen un conjunto de estados del proceso, de forma que los distintos modos de funcionamiento del mismo, pueden ser “cartografiados”.

Ejecutada sin más, la proyección SOM (al igual que el resto de las técnicas de reducción de la dimensión) genera lo que podríamos llamar un “mapa mudo” del proceso, que requiere una posterior identificación o interpretación de las regiones, es decir, se requiere una fase posterior que etiquete cada una de las regiones del mapa plano a los distintos estados y modos de funcionamiento del proceso. El SOM constituye realmente un modelo, una descripción simplificada o “resumen” del proceso que es además un mapa *asociativo* y *biunívoco* en el que todos los razonamientos sobre las neuronas del espacio de datos del proceso (cuyas variables son físicamente intuitivas) son directamente trasladables al plano de visualización. Esta asociación entre el proceso y un espacio visualizable permite literalmente conectar conceptos, modelos y reglas, válidas en el espacio de los datos del proceso, con imágenes o regiones que pueden ser visualizadas, lo que hace posible razonar visualmente con patrones gráficos e incorporar conocimiento *a priori* sobre el proceso a la tarea de exploración y “cartografiado” del modelo del proceso obtenido por el SOM.

A continuación se describen las técnicas que permiten esto. Para ello se definirá previamente el concepto de *plano* o *mapa*.

² A estos efectos, una medida habitual de distancia entre dos neuronas i y j es la *distancia de enlace*, dada por el número mínimo de enlaces a recorrer para ir del elemento i al elemento j .

Planos o mapas. Matemáticamente, un *plano* o *mapa* de una propiedad o característica escalar p viene definido por los elementos siguientes

$$\{\mathbf{g}_i, p_i\}_{i=1, \dots, N}$$

donde \mathbf{g}_i son las coordenadas del nodo i en el espacio de visualización, N es el número total de nodos del SOM y p_i es el valor de la propiedad escalar p para la posición \mathbf{m}_i en el espacio de los datos de proceso. Su representación gráfica más típica consiste en asociar a cada punto \mathbf{g}_i un nivel de color dado por p_i , lo que en el caso de un SOM con una estructura reticular rectangular da lugar a un mapa de colores que describe la distribución de los valores de la propiedad p para los datos de entrenamiento del modelo SOM.

Esta definición general permite, mediante una adecuada definición de la propiedad p , representar distintos tipos de información y conocimiento sobre el proceso que permiten un análisis visual exploratorio de su comportamiento y características que se exponen a continuación:

3.2.1. *Planos de componentes.* Matemáticamente, el plano de la componente j viene definido por los elementos siguientes

$$\{\mathbf{g}_i, m_{ij}\}_{i=1, \dots, N}$$

en el que la propiedad p viene dada por la componente j de cada unidad \mathbf{m}_i del SOM en el espacio de los datos de proceso. Los mapas resultantes, uno por cada variable del espacio de datos del proceso, son representativos del comportamiento de dicha variable en función de los estados del proceso.

Si asemejásemos el espacio de visualización del proceso a un mapa mudo de España, los planos de componentes aportarían una información similar a la que proporcionan los mapas de densidad de población, de índices de lluvias, producción de acero per-cápita, etc³. Viendo estos mapas, podemos clasificar y etiquetar las regiones del proceso usando conocimiento *a priori* sobre el proceso.

3.2.2. *Mapas de distancias interneuronales.* Estos mapas representan en el espacio de visualización la distancia promediada de una neurona a sus vecinas en el espacio de los datos. Las neuronas del SOM se agrupan en zonas en las que hay gran densidad de datos, por lo que estos mapas proporcionan información sobre la estructura de *clusters* o agrupamientos de los datos del proceso, correspondientes a condiciones o estados diferenciados.

³ En el caso del proceso hablaríamos de presiones, temperaturas, corrientes, energías de armónicos a frecuencias concretas, etc.

Un valor representativo de la distancia interneuronal para la neurona i puede obtenerse (Díaz, 2000) promediando la distancia entre dos neuronas \mathbf{m}_i , \mathbf{m}_j , por su grado de vecindad h_{ij} , lo que conduce a la siguiente expresión:

$$D_i = \frac{\sum_j h_{ij} d(\mathbf{m}_i, \mathbf{m}_j)}{\sum_j h_{ij}} \quad (2)$$

con lo que el mapa de distancias vendría definido por

$$\{\mathbf{g}_i, D_i\}$$

3.2.3. Mapas de Activación. A menudo se dispone de conocimiento del proceso en términos de casos, entendiendo por “caso” un subconjunto conocido de datos del proceso

$$S = \{\mathbf{x}_k\}_{k \in I_S}$$

que lleva aparejado un determinado conocimiento *a priori*, por ejemplo, datos de un proceso en estado de fallo cuyas causas se conocen.

Resulta posible obtener una representación de la región que describe el caso S mediante un histograma de los aciertos (veces que cada neurona es la que mejor describe un dato concreto) para ese conjunto de datos. Cada neurona i tendrá un índice de aciertos que puede ser representado en el espacio de visualización, induciendo una región correspondiente a aquella zona del espacio estimulada por el conjunto de los datos del caso (un ejemplo se muestra en la fig. 3). En (Díaz, 2000), se define la activación acumulada A_i para cada unidad i tras la introducción del caso S de la siguiente manera:

$$c(k) = \arg \min_i \{d(\mathbf{x}_k, \mathbf{m}_i)\}, \quad k \in I_S$$

$$A_i = \frac{\sum_{k \in I_S} h_{c(k)i}}{\sum_j h_{ij}} \quad (3)$$

En la expresión (3), cada neurona incrementa la activación debida a cada estímulo en función de su proximidad reticular a la neurona vencedora. El término del denominador es una medida de la influencia total ejercida mediante interacción lateral por todas las neuronas.

El mapa de activaciones para el caso S vendría definido por

$$\{\mathbf{g}_i, A_i\}$$

3.2.4. Mapas de modelos. Cualquier modelo matemático consistente en una relación funcional entre las variables x_1, \dots, x_n del espacio de datos, puede ser también representado en V . Por ejemplo, dado $\mathbf{x} = (x_1, x_2, \dots, x_n)^T$, si se sabe que, en determinadas condiciones, es válido el modelo

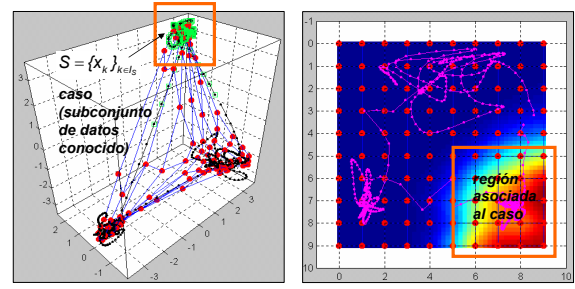


Figura 3. Mapa de Activaciones en el ejemplo de la figura 2

$$x_1 x_2 = x_3 \quad (4)$$

es posible definir un residuo del modelo

$$\epsilon(x_1, x_2, x_3, \dots, x_n) \equiv x_1 x_2 - x_3$$

que será nulo para puntos de funcionamiento \mathbf{x} del proceso que verifiquen el modelo y distinto de cero en caso contrario.

Así, para cada punto \mathbf{g}_i de V es posible hallar el valor del residuo para su homólogo $\mathbf{m}_i = (m_{i1}, m_{i2}, \dots, m_{in})^T$, lo que permite construir una *mapa de residuos*:

$$\{\mathbf{g}_i, \epsilon_i\}$$

donde,

$$\epsilon_i = \epsilon(\mathbf{m}_i) = m_{i1} m_{i2} - m_{i3}$$

Aquellas zonas de V con valores cercanos a cero describen las regiones en las que este modelo es válido, lo que permite conectar la intuición física que aporta el modelo con el modelo visual del proceso.

3.2.5. Planos Virtuales. Los planos virtuales permiten visualizar directamente modelos conocidos que relacionen variables del espacio de datos, D , con variables nuevas que tengan sentido físico. Así, por ejemplo, supóngase una variable v con sentido físico (por ejemplo, un índice de rendimiento o un factor de calidad) cuya relación funcional con las variables de D es conocida y viene definida por

$$v = f(x_1, x_2, \dots, x_n)$$

Dicha variable induce un nuevo plano o *plano virtual* aplicando sin más la función f a las componentes $m_{i1}, m_{i2}, \dots, m_{in}$ de la neurona i y representando en V el valor asociado al punto de coordenadas \mathbf{g}_i un nivel de color $v_i = f(m_{i1}, m_{i2}, \dots, m_{in})$, siendo el plano virtual

$$\{\mathbf{g}_i, v_i\}$$

Los modelos f pueden tener un origen *a priori* (leyes derivadas de la Física), como sería el caso de un plano virtual de potencia instantánea derivado del producto de una tensión por una corriente

$$P = f(V, I) = V \cdot I$$

o pueden haber sido derivados mediante procedimientos automáticos (ej. perceptrones multicapa o redes RBF) como sería el caso de un *clasificador* que devuelve una variable binaria de pertenencia a una clase dada

$$v_{clas} = f_{clas}(x_1, \dots, x_n), \quad v_{clas} \in \{0, 1\}$$

o un *sensor virtual* que estime una variable desconocida en función de otras variables conocidas del proceso

$$v_{sv} = f_{sv}(x_1, \dots, x_n), \quad v_{sv} \in \mathbb{R}^1$$

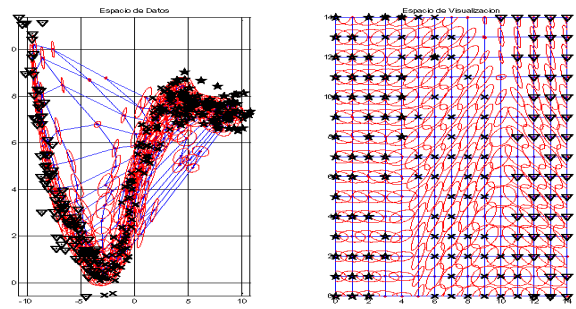
3.2.6. Mapas de Reglas. En procesos industriales a menudo se cuenta con abundante conocimiento acerca del proceso descrito en términos de un conjunto de reglas (bien difusas o bien “crisp”) que describa las relaciones entre diversas variables del proceso.

Un sistema de inferencia difusa (FIS, *Fuzzy Inference System*) que incorpora las etapas de fuzzyficación, inferencia y defuzzyficación, puede verse como un mapeo funcional entre las variables del espacio de los datos x_1, x_2, \dots, x_n y un conjunto de consecuentes definidos por sus grados de pertenencia μ_1, \dots, μ_p . Esto permite, mediante el procedimiento descrito anteriormente, construir planos virtuales con los grados de pertenencia de los consecuentes. Estos planos adquieren significado e intuición dado que representan los estados que verifican un conjunto de condiciones expresadas de forma lingüística por medio de reglas.


Por ejemplo, en el símil del mapa de España, si se sabe que en Asturias llueve mucho, y hay una densidad de población moderada-alta, y una elevada producción de acero per-cápita, es posible aplicar dicha regla a cada punto del país utilizando, por ejemplo, un sistema de inferencia borrosa y determinar un nivel de certeza del consecuente “la región es Asturias”. Los valores del consecuente, representados en el plano mediante tonos de color, marcarían aproximadamente Asturias.

3.2.7. Mapas de Correlaciones. En procesos no lineales las correlaciones entre las variables en la vecindad de un punto de funcionamiento (correlaciones locales) pueden variar en función del mismo. Así, las correlaciones evaluadas globalmente para todos los estados de funcionamiento pueden diferir considerablemente de las locales y no explicar adecuadamente las interrelaciones entre las variables.

En (Díaz *et al.*, 2002) se propone la definición del concepto de *correlación local*, evaluando para cada punto \mathbf{x} de D una matriz de correlaciones $\mathbf{R}(\mathbf{x})$ ponderando la contribución de cada dato \mathbf{x}_k del proceso según su proximidad a \mathbf{x} . Con este procedimiento se pueden obtener las correlaciones



(a) Covarianzas locales, mostradas en el espacio de datos (izquierda) y en el espacio de visualización (derecha)



(b) Mapas de correlaciones locales $r_{xx}, r_{xy}, r_{yx}, r_{yy}$.

Figura 4. Ejemplo: Noción de correlaciones locales.

locales existentes entre las variables del proceso x_1, x_2, \dots, x_n en el espacio de los datos para el entorno de cada \mathbf{m}_i y representarlas mediante códigos de color en cada uno de los nodos homólogos \mathbf{g}_i definidos en la retícula de V . Esta idea permite visualizar las correlaciones locales entre las variables del proceso para cada uno de sus puntos de funcionamiento, aportando una información clave en la comprensión y modelado del proceso.

Para ilustrar esta idea se muestra un sencillo ejemplo, con puntos en un espacio de datos de dos dimensiones simulando datos correspondientes a dos variables x, y de un proceso (figura 4(a)). Se distinguen claramente tres regiones de funcionamiento, marcadas con los símbolos “ \star ”, “ ∇ ” y “ \times ”, en las que el proceso opera de forma distinta. Para valores muy bajos o muy altos de x (regiones “ \star ” y “ ∇ ”), las dos variables x e y , están inversamente correlacionadas, mientras que para valores medios de x (región “ \times ”) la correlación es directa.

Esta situación puede visualizarse mediante los mapas de correlaciones. En la figura 4(a) se muestran las covarianzas locales, representadas en los

espacios de datos y de visualización. En la figura 4(b), se muestran los planos de las correlaciones r_{xx} , r_{xy} , r_{yx} , r_{yy} , en los que puede observarse cómo las correlaciones directas e inversas se corresponden con las condiciones de funcionamiento marcadas, apreciándose asimismo, la intensidad de la correlación, moderada en la región “★” e intensa en la región “▽”.

Este enfoque admite otras extensiones que actualmente están siendo exploradas por los autores, como la visualización de los vectores y valores propios de la matriz de covarianzas local, o la representación visual de otros estadísticos (ej. cumulantes).

3.3 Visualización de Residuos.

Las técnicas anteriores requieren, en principio, disponer de datos del proceso correspondientes a todos los estados que se pretenden analizar. Aunque esta circunstancia se suele dar (muchas veces el objetivo es detectar estados conocidos o explicar cosas que ya han ocurrido), existen procesos en los que se busca analizar una desviación de su comportamiento habitual hacia estados nuevos, en principio indefinidos, desconocidos.

Una disciplina de gran calado y con fuerte implantación en el campo de la supervisión es el análisis de residuos (Gertler, 1988; Gertler, 1992). Si se dispone de un modelo que explique el comportamiento del proceso en estado de funcionamiento normal es posible detectar la presencia de anomalías mediante el principio de *redundancia analítica* (Chow and Willsky, 1984), por comparación entre el modelo del proceso y el comportamiento real del mismo.

Los mapeos de reducción de la dimensión constituyen, como se dijo anteriormente, un modelo del proceso. En (Díaz, 2000; Díaz and Hollmen, 2002) se describe una técnica de visualización de los residuos sencilla pero efectiva basada en modelos neuronales autoasociativos (en principio, SOM, aunque son viables otras arquitecturas). Esta técnica consiste en hallar los residuos de cada variable por diferencia entre las variables del proceso y sus estimaciones de acuerdo con el modelo (ver figura 5), visualizando sus valores en una imagen bidimensional con tonos de gris o mapas de colores a lo largo del tiempo. Un comportamiento de acuerdo con el modelo daría residuos nulos (color verde). Cuando existe alguna anomalía, los residuos de las variables dan lugar a tonos rojos (variable por exceso, residuo positivo) o azules (viceversa). Esto permite, de un golpe de vista, no sólo detectar el fallo, sino las variables involucradas.

En la figura 6 se muestra la visualización de residuos aplicada sobre corrientes y vibraciones de un

motor asíncrono de 4 kW. La presencia de distintos tipos de fallos –combinaciones entre presencia de asimetría mecánica en el rotor y desequilibrios eléctricos graduales provocados mediante variación de la resistencia en una de las fases– así como las variables involucradas y los signos de las desviaciones son puestas de manifiesto visualmente a través de los residuos.

En (Díaz and Hollmen, 2002) se propone un razonamiento teórico que justifica algunas arquitecturas autoasociativas frente a otras a la hora de generar residuos intuitivos que permitan, no sólo la detección de un fallo, sino su identificación. Esta técnica de visualización ha dado hasta el momento resultados positivos y parece prometedora en su aplicación a la industria por su eficacia y sencillez.

4. APLICACIONES INDUSTRIALES DEL MODELADO VISUAL

4.1 Modelado visual de trenes de laminación

Las técnicas de modelado visual de procesos basadas en reducción de la dimensión descritas anteriormente son aplicables como ayuda al diagnóstico y a la evaluación del funcionamiento de un proceso de laminación en frío de chapa destinada a la producción hojalata en un tren tipo tándem.

Actualmente, tanto los espesores de la chapa como las tolerancias exigidas por los fabricantes de automóviles, latas de refrescos y conservas, etc. son cada vez más estrictas. En los últimos años se ha pasado de laminar con espesores objetivo del orden de $250 \mu\text{m}$ a laminar espesores por debajo de $200 \mu\text{m}$. Esta circunstancia hace cada vez más difícil mantener las tolerancias en la variación del espesor, que vienen dadas en valores relativos, lo que exige adoptar medidas orientadas a ajustar más el proceso.

Un tren tándem de laminación en frío es un proceso complejo, en el que intervienen multitud de factores tales como la excentricidad de los cilindros de laminación (cilindros de apoyo y de trabajo), las reducciones de espesor aplicadas en cada caja de laminación del tren, las propiedades elásticas del material laminado, las propiedades estructurales de cada una de las cajas del tren, velocidades de laminación, etc. Actualmente, no existe ningún modelo físico que considere satisfactoriamente todos estos factores de forma conjunta relacionándolos con la calidad (variación de espesor) obtenida en la bobina laminada (Roberts, 1997).

Las técnicas descritas fueron aplicadas a un tren tándem típico, en el que se dispone de más de 80 variables procedentes del ordenador de proceso, tomadas a intervalos de 1 segundo a lo largo de miles de bobinas. Se asume que estas 80 variables




Figura 5. Generación de residuos del SOM según $r(x) = x - m_c$

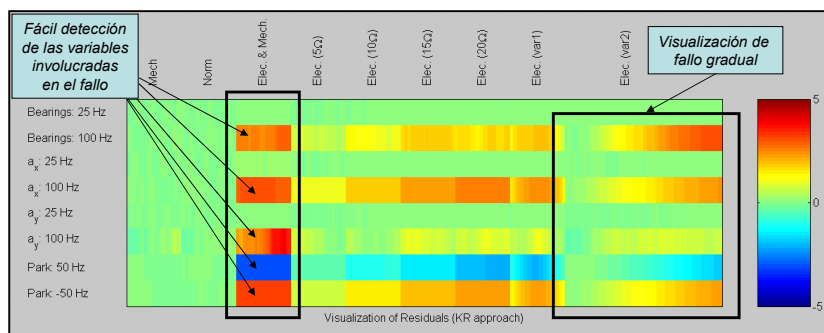


Figura 6. Visualización de Residuos. El eje x representa el tiempo; en el eje y se muestran las 8 características del proceso; en código de colores, se muestra el valor de los residuos.

definen con precisión suficiente la *condición* del proceso. Se dispone también de los índices de calidad de cada bobina (estadísticos de la variación de espesor) obtenidos a partir de una galga de rayos X instalada a la salida del tren. El principal objetivo es determinar qué variables del proceso tienen influencia sobre la calidad de las bobinas.

La técnica empleada para el análisis de esos datos consiste en un proceso de extracción de características seguido del entrenamiento de un modelo neuronal tipo SOM que establece una asociación (proyección) entre el espacio de los datos del tren (multidimensional) y un espacio de visualización 2D en el que se resumen los distintos estados del proceso en términos de regiones de dicho espacio. Las distintas bobinas y las condiciones en las que éstas fueron laminadas, junto con el valor de los índices de calidad, pueden representarse en dicho espacio de visualización permitiendo establecer correlaciones entre ellas (ver figura 7).

Otra técnica de visualización empleada en el análisis de los datos del tren de laminación es la visualización de los residuos generados por el mismo

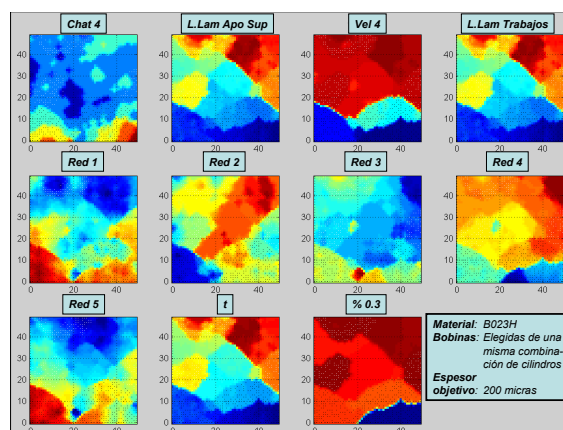


Figura 7. Planos de componentes correspondientes a 10 variables del tren más una variable de calidad (% de la bobina con espesor dentro de la banda de tolerancia $\pm 0,3\%$) permiten explorar por comparación visual los factores relacionados con la calidad del producto.

modelo del SOM empleado en la reducción de la dimensión. Para cada punto x del espacio de datos (medidas y/o características del proceso) se gene-

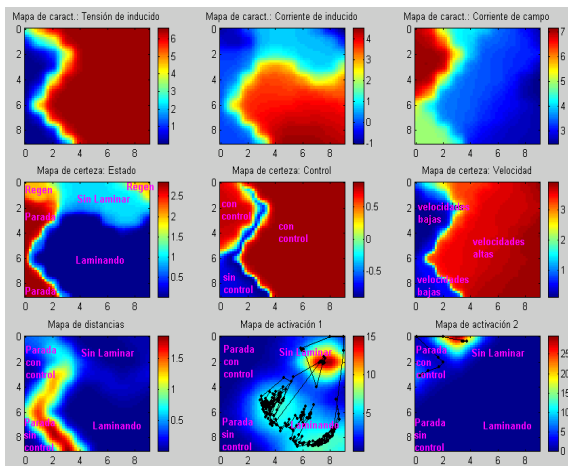


Figura 9. Incorporación de conocimiento previo en la visualización de un motor CC de 6000 kW. Los *mapas de activación* marcan regiones con los estados pertenecientes a un “caso” conocido y los *mapas de reglas* describen regiones con los estados que verifican un conjunto de reglas conocidas

ra la estimación más plausible \hat{x} , definiéndose el vector de residuos como la diferencia entre ambas tal y como se muestra en la figura 5.

La visualización de los residuos permite no sólo detectar situaciones anómalas, sino que además revela qué variables están desviadas respecto a sus valores deseados así como los sentidos de las desviaciones.

El vínculo que establece el modelo generado entre el espacio de datos y el espacio de visualización permite aplicar modelos conocidos en el primero y visualizarlos en el segundo. Esta idea permite conectar el conocimiento *a priori* disponible sobre el proceso (reglas borrosas, modelos parciales del proceso, etc.) con el modelo –proyección SOM– emanado de los datos. En la figura 9 se visualizan diversos mapas (de distancias, de características, de activación y de reglas difusas) aplicados a las variables fundamentales (tensión y corriente de inducido, velocidad y corriente de excitación) de un motor de CC de 6000 kW empleado en un tren de laminación para diferentes estados (laminando, no laminando, en regeneración, etc) en el que puede comprobarse cómo las representaciones de los distintos tipos de conocimiento son consistentes entre sí.

4.2 Monitorización on-line de la condición de procesos.

Otra de las posibilidades dentro del enfoque del modelado visual de procesos es la *monitorización de la condición en línea*. Como se describe en el apartado 3.1, el enfoque de la reducción de la dimensión permite proyectar en tiempo real

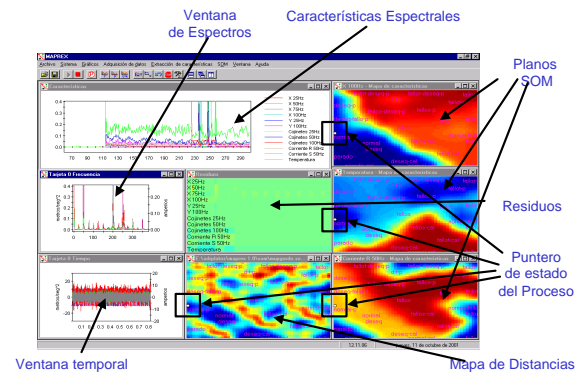


Figura 11. Pantalla del sistema de monitorización en línea basado en técnicas de modelado visual durante funcionamiento.

el vector de características del proceso sobre el espacio de visualización, lo que permite dar indicación de la condición del proceso de forma online. Habitualmente, la forma más apropiada de proceder es hacerlo por etapas tal y como se indica en la figura 1, incluyendo una etapa previa de selección/extracción de características y una segunda etapa de proyección.

En la figura 10 se presenta el diagrama de bloques de un sistema portátil para la monitorización online de la condición de procesos que emplea tecnología de modelado visual SOM, para la supervisión de procesos en los que interesa analizar armónicos (de corrientes, vibraciones, etc.). El sistema incorpora una etapa de reducción de la dimensión consistente en una extracción de características espectrales (energía de las señales en bandas de frecuencias), que habitualmente son seleccionadas a partir de la experiencia y el conocimiento adquirido del proceso. Estas características constituyen los datos de proceso que se proyectarán en el espacio de visualización mediante un SOM interpolado. Asimismo, tal y como se indica en la figura 10, el sistema permite la visualización de los residuos en tiempo real para la detección de condiciones anómalas no incluidas en el entrenamiento del modelo.

En la figura 11 se muestra una pantalla típica durante la operación del equipo, en la que, junto a visualizaciones tradicionales (evolución temporal de las variables del proceso, ventanas de espectros FFT), se representa el estado del proceso mediante un puntero, cuya trayectoria indica su condición de funcionamiento en función de las regiones que atraviesa.

5. CONCLUSIONES

El problema de conocimiento heterogéneo es muy común en una gran diversidad de áreas de la Ciencia y de la Tecnología con gran impacto en el mundo actual. Por una parte, existe una

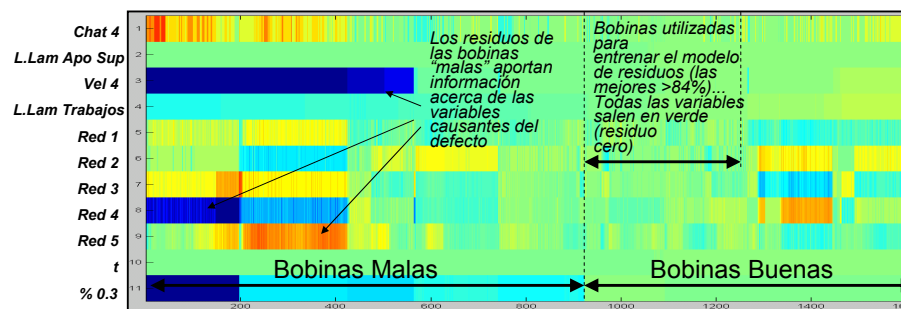


Figura 8. Visualización de Residuos de 11 variables del tren de laminación. Las variables que presentan desviaciones por exceso o por defecto respecto a los valores esperados por el modelo son puestas de manifiesto en la visualización. Éstas pueden además correlacionarse visualmente con la calidad del producto finalmente obtenido.

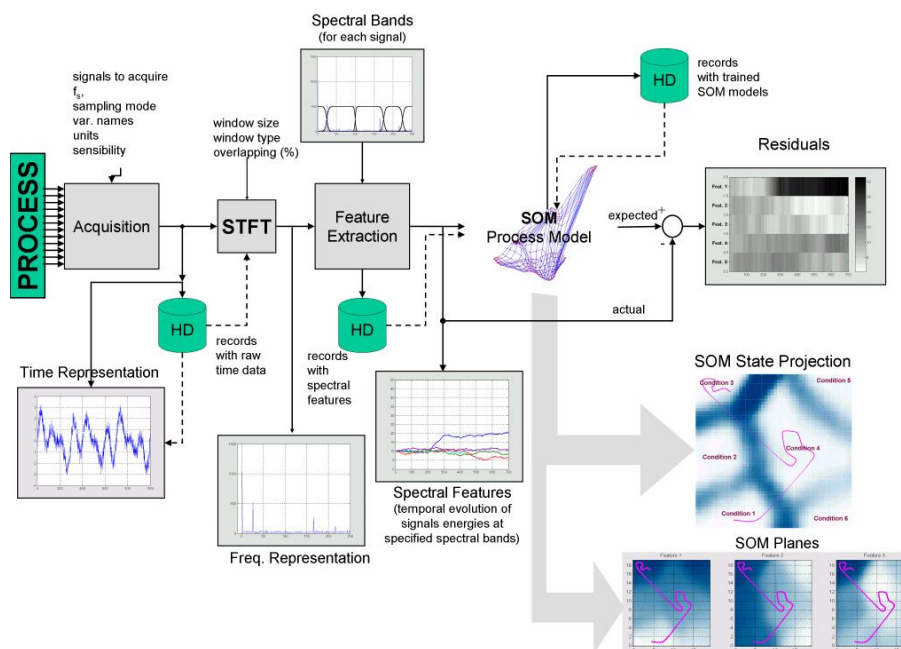


Figura 10. Diagrama de bloques del sistema de monitorización en línea.

abrumadora cantidad de información en forma de *datos* que requiere la búsqueda de modelos que los describan de forma más compacta, algo que persiguen las técnicas de Data Mining. Por otra parte, existe también conocimiento previo disponible en términos de *modelos*, un conocimiento de carácter inductivo, emanado de las experiencias de los expertos y de la literatura del área en cuestión (Ljung and Glad, 1994). Este conocimiento puede venir expresado de formas muy diversas – en términos de reglas, ecuaciones, casos, etc.–, a veces de una forma muy sutil, y que en ocasiones resulta completamente desaprovechado.

En este trabajo se ha presentado un conjunto de técnicas de visualización orientadas a la representación de distintos tipos de conocimiento asociado al proceso, incluyendo modelos físicos, casos, reglas y correlaciones, así como el propio estado del sistema. Las técnicas se basan en el principio de reducción de la dimensión que define

un *mapa del proceso* que representa –generalmente sobre un plano– los estados del mismo y sobre el que se definen, a modo de capas, las distintas representaciones, aportando una información similar a los mapas de temperaturas, presiones, índices demográficos, etc. de un país. Al definirse sobre un mismo mapa del proceso todas ellas son contrastables entre sí, lo que permite establecer de forma visual e intuitiva vínculos entre los distintos tipos de conocimiento disponibles, potenciando el proceso de reutilización y descubrimiento de conocimiento relativo a la naturaleza y el estado proceso.

Una línea de enorme potencial, actualmente investigada por los autores, es la extensión de las técnicas propuestas a la construcción de *mapas de la dinámica* del proceso, orientados a la visualización de los comportamientos dinámicos de procesos variantes en función de su punto de funcionamiento.

6. AGRADECIMIENTOS

Los autores agradecen el apoyo para este trabajo de la empresa Aceralia así como la financiación por parte del Ministerio de Educación y Ciencia y los fondos FEDER al proyecto de investigación DPI2002-01599 y la financiación europea fondos CECA (CECA-00-7210-PB/221, CECA-98-7210-PE/088-C).

7. REFERENCIAS

- Alhoniemi, Esa, Jaakko Hollmén, Olli Simula and Juha Vesanto (1999). Process monitoring and modeling using the self-organizing map. *Integrated Computer Aided Engineering* **6**(1), 3–14.
- Bishop, Christopher M., Markus Svensen and Christopher K. I. Williams (1998). GTM: The generative topographic mapping. *Neural Computation* **10**(1), 215–234.
- Card, Stuart, Jock Mackinlay and Ben Shneiderman (1999). *Readings in information visualization. Using vision to think*. Morgan Kaufmann Publishers, San Francisco.
- Chow, E. Y. and A. S. Willsky (1984). Analytical redundancy and the design of robust failure detection filters. *IEEE Transactions on Automatic Control* **7**, 603–614.
- Cuadrado, Abel A., Ignacio Díaz, Alberto B. Diez, Juan A. González and Faustino Obeso (2002). Visual data mining and monitoring in steel processes. In: *IEEE Industry Applications Society 37th Annual IAS Meeting*. Pittsburgh, PA, USA.
- Díaz, Ignacio (2000). Detección e Identificación de Fallos en Procesos Industriales Mediante Técnicas de Procesamiento Digital de Señal y Redes Neuronales. Aplicación al Mantenimiento Predictivo de Accionamientos Eléctricos.. PhD thesis. Universidad de Oviedo.
- Díaz, Ignacio, Abel A. Cuadrado and Alberto B. Diez (2002). Correlation visualization of high dimensional data using topographic maps. *Lecture Notes in Computer Science (LNCS)* **2415**, 1005–1010.
- Díaz, Ignacio, Abel Cuadrado, Alberto Diez, Luis Rodríguez Loredó, Faustino Obeso Carrera and Juan A. Rodríguez (2003). Visual predictive maintenance tool based on som projection techniques. *Revue de Métallurgie* **103**(3), 307–315.
- Díaz, Ignacio, Alberto B. Diez, Abel A. Cuadrado and Manuel Domínguez (2002). Prior knowledge integration in self organizing maps for complex process supervision. In: *International Federation of Automatic Control 15th IFAC World Congress*. Barcelona, Spain.
- Díaz, Ignacio and Jaakko Hollmen (2002). Residual generation and visualization for understanding novel process conditions. In: *International Joint Conference on Neural Networks (IJCNN, WCCI'2002)*. Honolulu, Hawaii, USA. pp. CD-ROM.
- Friedman, Jerome H. (1987). Exploratory projection pursuit. *Journal of the American Statistical Association* **82**(397), 249–266.
- Gertler, J.J. (1988). Survey of model-based failure detection and isolation in complex plants. *IEEE Control Systems Magazine* **8**(6), 3–11.
- Gertler, J.J. (1992). An evidential reasoning extension to quantitative model-based failure diagnosis. *IEEE Transactions on Systems, Man and Cybernetics* **22**(2), 275–289.
- Hotelling, Harold (1933). Analysis of a complex of statistical variables into principal components. *Journal of Educational Psychology* **24**, 417–441.
- Keim, Daniel A. (2001). Visual exploration of large data sets. *Communications of the ACM* **44**(8), 39–44.
- Kohonen, Teuvo (1995). *Self-Organizing Maps*. Springer-Verlag.
- Kohonen, Teuvo, Erkki Oja, Olli Simula, Ari Visa and Jari Kangas (1996). Engineering applications of the self-organizing map. *Proceedings of the IEEE* **84**(10), 1358–1384.
- Ljung, Lennart and Torkel Glad (1994). *Modeling of Dynamic Systems*. Prentice-Hall, Inc.
- Raivio, Kimmo, Olli Simula and Jaana Laiho (2001). Neural analysis of mobile radio access network. In: *Proceedings of the International Conference on Data Mining (ICDM)*. San José. pp. 457–464.
- Roberts, C. David (1997). Mechanical principles of rolling (part i). *Iron and Steelmaker* **24**, 113–114.
- Roweis, Sam T. and Lawrence K. Saul (2000). Nonlinear dimensionality reduction by locally linear embedding. *Science* **290**, 2323–2326.
- Sammon, John W. (1969). A nonlinear mapping for data structure analysis. *IEEE Transactions on Computers* **C-18**(5), 401–409.
- Tenenbaum, Joshua B., Vin de Silva and John C. Langford (2000). A global geometric framework for nonlinear dimensionality reduction. *Science* **290**, 2319–2323.
- Torgerson, W. (1958). *Theory and Methods of Scaling*. Wiley.
- Wilson, David J. H. and George W. Irwin (1999). RBF principal manifolds for process monitoring. *IEEE Transactions on Neural Networks* **10**(6), 1424–1434.
- Wong, Pak Chung (1999). Visual data mining (guest editor introduction). *IEEE Computer Graphics and Applications*.