

AISLAMIENTO DE FALLOS POR ESTIMACIÓN DE PARÁMETROS CON TÉCNICAS NEURONALES

R. Ferreiro García
ETSNM. Paseo de Ronda 51 15011 A Coruña. ferreiro@udc.es

M. Meizoso, A. Piñón Pazos
E.U.P. Carretera de. Aneiros s/n, 15405 Ferrol. mmeizoso@cdf.udc.es, andrespp@cdf.udc.es

Resumen

El artículo aborda un novedoso método para la estimación de parámetros inherentes a procesos no lineales y de difícil medida utilizando masivamente redes neuronales entrenadas mediante propagación hacia atrás para ser utilizado en la detección y aislamiento de fallos en procesos físicos. La herramienta para la utilización masiva de redes neuronales es una parte de DeltaV y permite su implementación dentro de arquitecturas de control basadas en el estándar Foundation Fieldbus.

Palabras Clave: Redes de Neuronas, Aproximación funcional, Propagación hacia atrás, Modelización inversa, Detección de fallos, Aislamiento de fallos.

1 NOCIONES SOBRE TÉCNICAS DE ESTIMACIÓN

Las especificaciones sobre la calidad de productos asociada con la complejidad operacional de los procesos crece exponencialmente. Con el objeto de aminorar o aliviar los requerimientos operacionales asociados con tales demandas, la conducción y vigilancia de las plantas queda a expensas de las últimas herramientas y técnicas dentro del estado del arte. Con objeto de conseguir un comportamiento adecuado acorde con las especificaciones, los procesos tienen que operar libres de fallos. La supervisión de procesos consiste en la tarea responsable de detectar y corregir fallos mediante tareas de monitorización.

Los tipos de fallos hallados en aplicaciones industriales está clasificados por lo general en algunos de los siguientes grupos:

- Cambios de parámetros de los procesos
- Cambios de parámetros de perturbación
- Funcionamiento incorrecto en actuadores
- Funcionamiento incorrecto en sensores

La secuencia de sub-tareas a llevar a cabo para asegurar la correcta operación de un proceso constituye el cuerpo principal del proceso de supervisión generalmente referido a las tareas de monitorización, las cuales incluyen:

- Detección de fallos,
- Identificación de fallos,
- Diagnóstico de fallos y
- Eliminación de fallos mediante técnicas de intervención, recuperación del proceso o reconfiguración.

La monitorización de procesos está basada en procedimientos de adquisición y procesamiento de información. Las tareas de monitorización pueden clasificarse en una o mas de las siguientes aproximaciones:

- Conducidos por datos
- Analíticas
- Basadas en conocimiento

Conducidos por datos.- La eficiencia de los métodos basados en datos, los analíticos y los basados en conocimiento dependen de la calidad y tipo de modelos y en la calidad y cantidad de datos disponibles. PCA o (Principal Component Análisis) es el método conducido por datos mas ampliamente utilizado. Consiste en una técnica de reducción óptima de dimensiones en términos de captura de la variancia de la información en busca de la correlación entre variables (Jackson J. E., 1956), (Jackson J. E., 1959). La estructura extraída del PCA puede ser útil en la identificación de variables responsables de fallos y/o variables afectadas por fallos.

FDA (Fisher Discriminant Análisis) es una técnica de reducción dimensional desarrollada por la comunidad de reconocimiento y clasificación de patrones (Duda R. O. And Hart P. E., 1973). FDA determina la porción del espacio de observación que resulta mas efectivo en la discriminación entre varias clases de datos, siendo utilizado en diagnóstico de fallos. Mínimos cuadrados parciales (PLS) aplica métodos de descomposición para maximización de la

covarianza entre bloque predictor y bloque precedido para cada componente (Wise B. M. And Gallagher N. B. 1996), (MacGregor J. F., 1994) (Piovoso M. J. and Kosanovich K. A. 1994), (Piovoso M. J. and Kosanovich K. A. 1992).

Analítico.- Los métodos analíticos que utilizan residuos como rasgos, están referidos a los métodos analíticos redundantes. Consisten en aplicar un chequeo de consistencia entre las observaciones de la planta y del modelo. Los residuos deben ser suficientemente amplios bajo presencia de fallos y muy pequeños ante presencia de perturbaciones, ruido y errores de modelado (Frank P. M., 1993), (Gertler. J. J. 1998), (Hodouin D. And Makni 1996). Existen tres métodos principales para generar residuos:

- Estimación de parámetros
- Observadores
- Relaciones de Paridad

En el caso de estimación de parámetros, los residuos son la diferencia entre los valores nominales de los parámetros del modelo y los valores estimados de los parámetros del modelo. Los desvíos en los parámetros del modelo indican la presencia de algún fallo o cambio. (Bakiotis C. et all. 1979), (Isserman R. 1998), (Isserman R. 1993), (Mehra R. K. And Peschon J. 1971).

En los métodos basados en observadores, la salida del sistema es reconstruida a partir de las medidas con ayuda de los observadores. La diferencia entre la salida actual medida y la salida estimada proporciona los residuos (Frank P. M., 1990), (Clark R.N. et all. 1975), (Ding X. And Guo L. 1996).

La estrategia basada en relaciones de paridad compara la consistencia del modelo matemático del sistema con las medidas reales actuales. Las relaciones de paridad están sujetas a una transformación dinámica lineal con los residuos transformados utilizados en las tareas de detección y aislamiento de fallos (Gertler. J. J. 1998), (Mironovski L. A. 1979), (Mironovski L. A. 1980).

Basadas en conocimiento.- Los métodos basados en conocimiento, usados masivamente en tareas de monitorización incluyen:

- Análisis Causal
- Sistemas Expertos
- Reconocimiento de Patrones

Tales técnicas están basadas en modelos cualitativos, que podrían ser obtenidos mediante

- Modelización causal de los sistemas,
- Conocimiento experto,
- Un modelo detallado del sistema o,
- Casos basados en síntomas de fallo.

Las técnicas de análisis causal están basadas en la modelización causal de la relación síntoma-fallo. Estas técnicas incluyendo grafos directos signados y árboles de síntomas son principalmente utilizadas en diagnosis de fallos (Lee G. et all.1999), (Mo K. J. et all. 1997), (Mo K. J. et all. 1998).

Los sistemas expertos son utilizados bajo un modelo de razonamiento típicamente humano. La experiencia de expertos de un dominio puede ser formulada en términos de conocimiento acumulado en una base de reglas, aplicada con éxito a la diagnosis de fallos (Kramer M. A. and Finch F. E. 1988), (Li. T. 1989). En contraste con este método que utiliza conocimientos superficiales basados en la experiencia, se utilizan conocimientos mas profundos basados en cálculos analíticos que implican cálculos fundamentales de ingeniería, la descripción estructural del sistema o una completa descripción del comportamiento de sus componentes ante condiciones de fallo y de operación normal (Kramer M. A and Palowitch J.B.L. 1987), (Kramer M. A. and Finch F. E. 1988)..

Se utilizan masivamente sistemas expertos mas avanzados que operan con técnicas de aprendizaje implementadas sobre redes de neuronas artificiales (ANN) (Bakshi B.R. and Stephanopoulos G. 1994).

Las técnicas basadas en el reconocimiento de formas utilizan la asociación de patrones de información con clases de fallos sin un modelo explícito de los estados internos del proceso o estructura. Las ANN los mapas auto-organizativos basados en aprendizaje no supervisado conocidas como *Kohonen self-organising map*, constituyen la herramienta principal (Doyle R. J. et all).

Una técnica extensivamente utilizada en diagnosis de fallos basada en ANN emplea la estructura neuronal de propagación hacia atrás (Nekovie, R., and Sun, Y., 1995). Así en esta línea de desarrollo se emplean ANN basadas en propagación hacia atrás a estrategias de toma de decisiones basadas en reglas (Ali Zilouchian and Khalid Bawazeer. 2001), (Demuth, H. And Beale, M.1998).

En absoluto, ningún método citado de diagnosis de fallos resulta por si sólo plenamente efectivo. Para obtener resultados prácticos se hace necesaria la combinación de varios procedimientos. Generalmente el mejor esquema de monitorización de procesos complejos incluye la asociación de varios métodos

Este artículo está centrado en la descripción de la metodología para la determinación de parámetros utilizada en la detección de fallos, localización identificación y diagnosis incluyendo la toma de

decisiones basada en conocimiento mediante técnicas inferenciales de evaluación de reglas.

Para llevar a cabo la tarea propuesta se hace uso masivo de bloques función neuronales, que utilizan el algoritmo de entrenamiento de propagación hacia atrás por medio de la herramienta DeltaV Neural (DeltaV™ 2001).

El tópico mas relevante de la contribución reside en la aplicación de la tecnología para la utilización masiva de ANNs. La arquitectura de ANNs propuesta puede predecir con precisión varias propiedades asociadas con el comportamiento del proceso. Las ANNs bajo arquitecturas por propagación hacia atrás (BPNN) suponen las ANN predictivas por adelantado mas populares que se utilizan en la industria. Una ANN entrenada por medio del algoritmo de propagación hacia atrás asume que todos los elementos y conexiones son responsables de generar la diferencia entre la salida actual y la esperada. El algoritmo de entrenamiento consiste en un algoritmo del gradiente descendente interactivo diseñado para minimizar el error cuadrático medio (RMS) entre la salida actual y la salida deseada, requiriendo un espacio de operación no lineal continuo derivable.

2 MODELIZACIÓN CON ANNs

No es frecuente operar con sistemas lineales porque un sistema es lineal si todos sus elementos lo son y es no lineal si uno sólo de sus elementos es no lineal. Por tal razón, los procesos industriales son generalmente no lineales. Por otra parte, los sistemas de parámetros concentrados no existen en la realidad física. Los parámetros de procesos comunes son distribuidos en lugar de concentrados y finalmente, tales sistemas son variantes en el tiempo. Con tal escenario, cualquier intento de modelado de un proceso industrial por medios analíticos podría fracasar a menos que se asuma y tolere un gran error de modelado. Tales inconvenientes pueden ser reducidos o minimizados aplicando métodos alternativos de modelado por aproximación funcional. La aproximación funcional ha sido extensivamente utilizada en muchas aplicaciones industriales de donde se tienen algunos trabajos recientes (Bawazeer, K. H., 1996), (Bawazeer, K. H. and Zilouchian, A., 1997). No obstante, en este trabajo la aproximación funcional es utilizada por implementación sobre ANN. Aquí, los parámetros variantes en el tiempo de los procesos variantes son considerados como variables de proceso desde el punto de vista de la modelización. Tal concepto de modelado es llevado a cabo mediante ANN entrenadas por medio del algoritmo BP. Con tal asunción, un proceso puede ser descrito mediante un

juego de variables clasificadas como comandos de entrada, perturbaciones, variables internas, variables de salida, parámetros variables, parámetros constantes y en general todos los parámetros y variables relacionados por una dependencia funcional entre sí y almacenados en una base de datos bajo ciertas condiciones de restricción.

Los procesos causales pueden ser modelizados mediante dispositivos de aproximación funcional. Una propiedad causal de la modelización es utilizada aquí no solo para predecir la relación entrada / salida del estado estacionario sino la relación dentro del estado transitorio. Con el objeto de reafirmar el concepto de modelización en base a las ANNs (NNBM), consideremos un proceso causal descrito mediante aproximación funcional, donde V_1 es la salida, V_2, V_3, \dots, V_N son variables de entrada incluidas sus derivadas sucesivas y P_1, P_2, \dots, P_J son parámetros del proceso. Con tal notación, se puede expresar la relación funcional según

$$V_1 = f(V_2, V_3, \dots, V_N, P_1, P_2, \dots, P_M) \quad (1)$$

Dada la base de datos constituida por datos causales procedentes del proceso descrito por (1), se puede establecer las siguiente relaciones:

$$\begin{aligned} V_1 &= f(V_2, V_3, \dots, V_N, P_1, P_2, \dots, P_J), \\ V_2 &= f(V_1, V_3, \dots, V_N, P_1, P_2, \dots, P_J), \\ P_1 &= f(V_1, V_2, \dots, V_N, P_2, P_J), \\ P_J &= f(V_1, V_2, \dots, V_N, P_1, P_2) \end{aligned} \quad (2)$$

donde $V_1 = f(V_2, V_3, V_N, P_1, P_2, \dots, P_J)$ en (2) es un modelo directo de predictor (DMP), y cualquier otra relación funcional en (2) son modelos inversos de predictores (IMP).

Las ANN en sus versiones DMP o IMP no resultan suficientemente precisas si la información de entrada / salida está fuera del rango para el han sido entrenadas. Así que los datos útiles para la base de datos deben estar comprendidos dentro del rango de máxima variación del proceso. La dimensionalidad de la base de datos (DBS) es seleccionada de acuerdo con la precisión requerida a la NNBM. Generalmente el tamaño de la base de datos puede ser definido como el producto del número de variables involucradas en una función por el número de juegos de datos (NDS) que involucran todas las variables. De acuerdo con esta definición se tiene que

$$\begin{aligned} NDS &= \prod_{i=1}^{NV} DP_i, \\ DBS &= NV \cdot \prod_{i=1}^{NV} DP_i \end{aligned} \quad (3)$$

donde DP_i es el número de puntos de captura de cada variable (i) y NV es el número de variables de entrada / salida incluyendo parámetros variables de la función .

Cada juego de datos muestreado será válido si todos los valores capturados representan las variables físicas con precisión. Por tanto, deben tomarse ciertas precauciones de procesamiento de datos antes de admitir los juegos de datos como válidos. Para resumir la tarea de captura, almacenamiento y utilización de los datos necesarios en el entrenamiento mediante propagación hacia atrás de las NNBM se ilustra tal concepto por medio de la figura 1

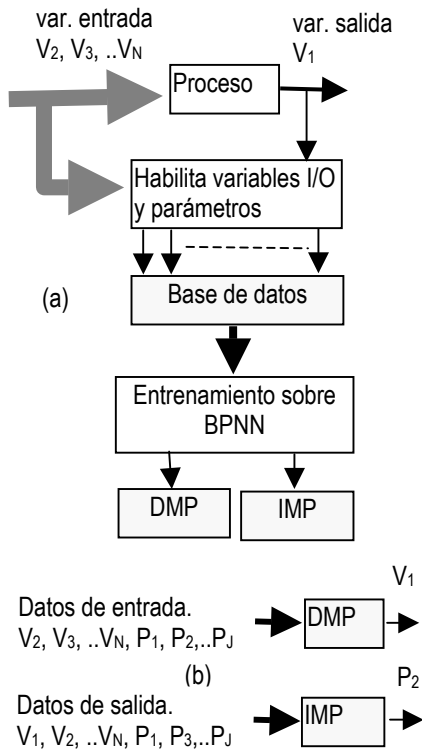


Fig. 1. Adquisición continua de datos de un proceso sencillo, almacenamiento, y entrenamiento. (a) Adquisición y entrenamiento. (b) Aplicación de DMP y IMP.

2 METODOLOGÍA PROPUESTA PARA LA ESTIMACIÓN DE PARÁMETROS

Los métodos convencionales de estimación de parámetros son apropiados si los fallos susceptibles de aparecer en un proceso están asociados al cambio de valores en los parámetros del proceso, tal como en el caso de fallos multiplicativos y cuando se disponga de modelos rigurosos del proceso. No obstante, en casos de parámetros distribuidos, procesos tiempo variante y no lineales, los métodos convencionales

tales como el de mínimos cuadrados, no son suficientemente efectivos.

Los errores de modelado pueden ser reducidos drásticamente aplicando las técnicas de modelización por aproximación funcional. La aproximación funcional de la forma expuesta en (2) y basada en BPNN es propuesta en este trabajo para detectar el desvío entre los valores nominales de los parámetros y los valores actuales estimados. Para exponer el procedimiento, tomemos en consideración un proceso definido en función de sus variables de entrada / salida y sus parámetros accesibles.

$$V_1 = f(V_2, V_3, \dots, V_N, P_1, P_2, \dots, P_M), \quad (4)$$

Después de conseguir una base de datos con información relacional entre variables y parámetros asociados a la expresión (4) y la consecuente tarea de entrenamiento utilizando un algoritmo de BPNN, resulta la siguiente NNBM capaz de estimar el valor actual del parámetro \hat{P}_1 según la expresión

$$\hat{P}_1 = f(V_1, V_2, \dots, V_N, P_2, P_J), \quad (5)$$

La figura 2 muestra el esquema del bloque función neuronal estructurado para ser entrenado y aplicado con variables accesibles en tiempo real capaz de estimar el citado parámetro

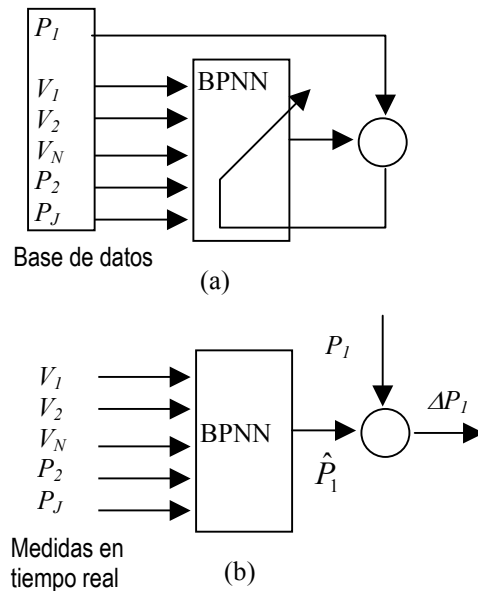


Fig. 2. Bloque función para estimación de un parámetro: (a), fase de entrenamiento. (b), estimación en tiempo real.

Si la variación de un parámetro está asociada con un fallo, entonces la diferencia entre el valor nominal y en valor actual generada, denominada residuo es utilizada como dato para detectar la presencia de fallo

$$\Delta P_j = P_j - \hat{P}_j, \quad (6)$$

Tal diferencia constituye la prueba de la variación de algún parámetro y consecuentemente, de la existencia de una anomalía o fallo causante de la citada variación de parámetros. Aún cuando no existan fallos en la planta, ΔP_j no se anula debido a la presencia de perturbaciones no medidas, ruido y posible error de modelado. Los procesos reales son estocásticos y por tanto debe establecerse un umbral a partir del cual se debe considerar la existencia de fallo. Así se considera la presencia de fallo si ΔP_j sobrepasa el citado umbral (detección del fallo). Los parámetros asociados con la violación del citado umbral son aquellos asociados al fallo responsable de la variación (aislamiento del fallo).

El descubrimiento de parámetros asociados con fallos de la planta resulta útil en algunos problemas de monitorización. La metodología propuesta podría sustituir los métodos convencionales de estimación de parámetros (p.e., mínimos cuadrados) en las tareas de detección y aislamiento de fallos con la ventaja inherente debida a la reducción o cancelación del error de modelado.

3 IMPLEMENTACIÓN DEL METODO DE DETECCIÓN DE FALLOS NMEDIANTE ESTIMACIÓN DE PARÁMETROS

Nos proponemos ilustrar el método propuesto de detección de fallos, por medio de dos ejemplos de aplicación muy general en la industria.

3.1 CASO 1: TRANSFERENCIA DE UN FLUIDO LÍQUIDO EN TANQUE CERRADO

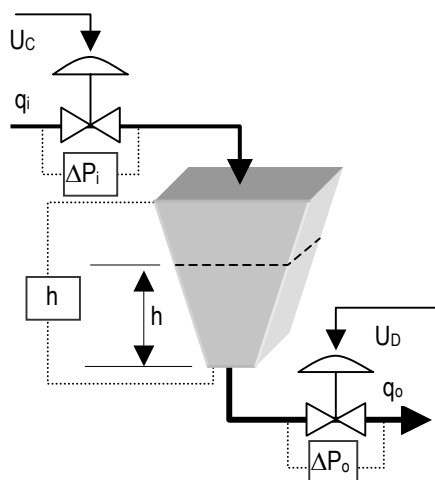


Fig. 3. Sistema de tanque cerrado

El sistema está regido por la ecuación de balance de materia según:

$$q_i - q_o - L = A(h) \frac{dh}{dt} \quad (7)$$

donde $A(h)$ es el área de la sección transversal del tanque, h es el nivel de líquido, L es el parámetro asociado con una pérdida o fuga de fluido, el cual identifica la fuga no solamente del tanque sino de las líneas de entrada y salida entre ambas válvulas, F_i es el caudal volumétrico de entrada y F_o es el caudal volumétrico de salida.

La monitorización de las válvulas está implementada sobre a base de la aproximación funcional neuronal según:

$$q_i = f(U_C, \Delta P_i) \quad (8)$$

$$q_o = f(U_D, \Delta P_o) \quad (9)$$

donde U_C y U_D son señales de comando a las respectivas válvulas, y ΔP_i y ΔP_o son los gradientes de presión de las válvulas.

Mediante el procedimiento de aproximación funcional se consigue el modelo DMP como:

$$q_i = f(q_o, L, h, \dot{h}) \quad (10)$$

Consecuentemente, aplicando la misma metodología se obtiene un modelo IMP que describe la dinámica del parámetro de fugas L como:

$$L = f(q_i, q_o, h, \dot{h}) \quad (11)$$

Tal parámetro debe aproximarse a cero o anularse para concluir que no existen fugas.

El esquema de la figura 4 ilustra la función descrita por la expresión (11). La misma estructura está implementada bajo un modelo NNBM con redundancia para los caudales de entrada y salida en la figura 5.




Fig. 4 Aproximación funcional para detectar el parámetro L (fugas).

En este caso los caudales son validados antes de entrar el bloque NNBM responsable de determinar el parámetro L . Bajo tal esquema el parámetro L es validado con la condición de existencia de un residuo dado como la diferencia entre los caudales nominal y actual. De aquí se sigue que la toma de decisiones puede ser llevada a cabo por medio de un procedimiento basado en reglas.




Fig. 5. Aproximación funcional con redundancia para detectar el parámetro L (fugas).

3.2 CASO 2: EFICIENCIA PROPULSIVA DE UN VEHÍCULO MARINO

La eficiencia propulsiva de un buque en términos de fricción del casco podría ser detectada por la variación de un parámetro tiempo variante capaz de identificar el coeficiente que relaciona la fuerza de fricción con la velocidad

La relación entre las variables involucradas en la función que describe este fenómeno puede expresarse bajo un modelo de aproximación funcional en base a una BPNN.

La fuerza propulsora desarrollada por una hélice de paso controlable puede ser expresada como

$$E = f(\omega, v, p) \quad (12)$$

donde E es la fuerza de propulsión, w es la velocidad angular de la hélice, p es el paso actual de la hélice y v es la velocidad de avance del buque.

De la misma manera, tal fuerza propulsora puede ser expresada bajo otra dependencia funcional en función de la masa del buque m , su velocidad y derivada respecto del tiempo, así como de un coeficiente de fricción hidrodinámica K_D según

$$E = f(m, v, \dot{v}, K_D) \quad (13)$$

Al aplicar la propiedad de modelización inversa a (13), se obtiene para el coeficiente de fricción la siguiente expresión

$$K_D = f(m, v, \dot{v}, E) \quad (14)$$

la cual es susceptible de ser implementada mediante un IMP bajo el modo de BPNN.

Por lo tanto, combinando (12) y (14) se obtiene la fuerza de fricción según se muestra en la figura 6, la cual detecta cualquier fallo relacionado con la eficiencia propulsiva, tal como suciedad del casco, cambio de la forma de la superficie mojada por variación de las condiciones de carga o la alteración del medio por variación de condiciones meteorológicas y en general por variación de cualquier fuerza capaz de afectar la resistencia a la marcha.




Fig. 6. Estructura de aproximador funcional en base a una BPNN para detectar cambios del parámetro K_D

3.3 RESULTADOS DEL CASO 2

En la figura 7 se muestran algunos resultados por simulación de un vehículo marino de masa 1.000.000 kg. No son necesarios los parámetros característicos del buque a excepción de un coeficiente de fricción hidrodinámico nominal ($K_{Dnominal}$). En la primera gráfica de la citada figura se aprecia la respuesta temporal del empuje y su correspondiente velocidad como función del paso y revoluciones del propulsor mostradas en la gráfica tercera de la figura 7. Asimismo, en la segunda gráfica se muestra la evolución del parámetro de fricción hidrodinámica o resistencia a la marcha (K_{Dreal}) por medio del residuo o diferencia entre los parámetros K_{Dreal} y $K_{Dnominal}$, en donde se aprecia la independencia de este parámetro frente a la variación del empuje y velocidad del buque. A los 300 s de tiempo comienza a elevarse el valor del residuo cesando a los 400 s., el cual permanece constante a lo largo del estudio. Este cambio del residuo es debido a la variación del parámetro K_{Dreal} . Con el cambio observado (detección), se ha interpretado como un cambio en el comportamiento del parámetro K_{Dreal} pasando de 0 a 6000, el cual, si está asociado a algún fallo, proporciona la información para determinar la causa del mismo (localización). Para localizar la causa es necesario disponer a priori de ciertos conocimientos relacionados con las posibles causas de fallo, de

modo que por análisis del entorno de existencia de las causas de fallo es posible descartar aquellas de las que no existen síntomas. Así, en este caso, resulta que al aparecer el residuo de modo abrupto se deduce que no se debe al estado de suciedad del casco ya que no existe ensuciamiento gradual del casco sino paulatino. Sin embargo, se han detectado causas o perturbaciones al medio capaces de generar tal situación, esto es, corrientes marinas de dirección opuesta al del avance del buque, lo cual aumenta la resistencia a la marcha. Al entrar el buque en una zona de corrientes de sentido contrario aumenta la resistencia a la marcha, lo cual es detectado y aislado por exclusión de otras perturbaciones accesibles y por tanto medidas, tal como el viento o el oleaje. El coeficiente de resistencia a la marcha o de fricción hidrodinámica no es directamente medible con lo cual tiene que ser determinado por exclusión de las demás perturbaciones. Por tanto KDreal puede solamente ser hallado de modo determinista en ausencia de las demás perturbaciones. El análisis global para la toma de decisiones es realizado en base a los razonamientos establecidos y es procesado mediante sencillas reglas.

4 IMPLEMENTACIÓN DEL SISTEMA

La implementación de la metodología propuesta ha requerido la utilización de una herramienta denominada DeltaV Neural que satisface el estándar FOUNDATION™ Fieldbus (DeltaV™ 2001). Esta herramienta facilita el uso masivo de redes de neuronas orientadas a la solución de problemas susceptibles de ser resueltos mediante aproximación funcional bajo un entorno virtual de ingeniería orientado a objetos.

DeltaV Neural es parte de DeltaV y tiene sus raíces en las redes neuronales multi-capas de adelanto entrenadas mediante el algoritmo de propagación hacia atrás. Comparadas con otros productos basados en las redes neuronales tradicionales, esta herramienta dispone de facilidades de manipulación avanzadas tales como actualización automática o auto-adaptación en base a un analizador de información o "lab entry" que elabora las nuevas muestras estimando las muestras futuras por predicción de la tendencia. La precisión en la estimación de las medidas está sustancialmente mejorada como resultado de tales aportes.

5 DISCUSIÓN Y CONCLUSIONES

Se ha presentado una metodología coherente y sistemática para implementar tareas de monitorización dotadas de procedimientos de estimación de parámetros para la detección de

cambios (fallos) y su localización por medio del uso de predictores basados en BPNN de modo masivo.

La habilidad de este algoritmo para proporcionar de modo directo los valores de parámetros del proceso o sistema así como variables, supone la característica más relevante del trabajo. Esta característica satisface las demandas de la mayoría de las tareas de monitorización o supervisión de procesos.

Como consecuencia del uso de herramientas basadas en el estándar FOUNDATION™ Fieldbus y concretamente de la herramienta DeltaV Neural, no es necesario un conocimiento detallado o profundo acerca de manejo de las redes de neuronas ni de los algoritmos de entrenamiento.

La disponibilidad de tales herramientas hace posible tales aplicaciones con mucho menor esfuerzo tanto de diseño o desarrollo como esfuerzo computacional.

Agradecimientos

Los autores desean mostrar su agradecimiento por el soporte financiero asignado al proyecto español DPI2003-00512 desde el MCYT y FEDER.

Referencias

- [1] Ali Zilouchian and Khalid Bawazeer (2001). Application of neural networks in oil refineries. *Intelligent Control Systems Using Soft Computing Methodologies*, ed. by Ali Zilouchian Mo Jamshidi. CRC Press, 2001, pp 139-158. USA
- [2] Bakiotis C. et al. 1979. Parameter and Discriminant Analysis for jet engine mechanical state diagnosis. *Proc. Of the IEEE Conf. On Decision and Control*, pp 11-1. Piscataway, New Jersey. IEEE Press.
- [3] Bakshi B.R. and Stephanopoulos G. 1994. Representation of process trends, IV Induction of real time patterns from operating data for diagnosis and supervisory control. *Computers and Chemical Engineering*, 18: pp 303-332.
- [4] Bawazeer, K. H., (1996). *Prediction of Crude Oil Product Quality Parameters Using Neural Networks*, MS Thesis, Florida Atlantic University, Boca Raton, FL, August
- [5] Bawazeer, K. H. and Zilouchian, A., (1997) Prediction of Crude Oil Production Quality Parameters Using Neural Networks, *Proc. Of IEEE int. Conf. On Neural Networks.*, New Orleans.
- [6] Clark R.N. et al. 1975. Detecting instrument malfunctions in control systems. *IEEE Trans. On Aerospace and Electronic Systems*, 11:465-473.
- [7] Deckert J.C. et al. 1977. F-8 DFBW sensor failure identification using analytic

- redundancy. *IEEE Trans. On Automatic Control*, 22: 795-803.
- [8] DeltaV™. V.5.3. (2001), Books on line. Copyright © 1994-2001, Fisher-Rosemount Systems, Inc., Emerson process Management. USA
- [9] Demuth, H. And Beale, M., (1998). *Neural Network Toolbox for Use with MATLAB*, the Math Works Inc., Natick, MA, USA.
- [10] Ding X. And Guo L. 1996. Observer based fault detection optimised in the frequency domain. *Proc. Of the 13th IFAC World Congress*, Vol N, pp. 157-162. Piscataway, New Jersey. IEEE Press.
- [11] Doyle R. J. et all. 1993. Causal modelling and data-driven simulation for monitoring of continuous systems. *Computers in Aerospace*, 9:395-405
- [12] Duda R. O. And Hart P. E., 1973. *Pattern Classification and Scene Analysis*. John Wiley & Sons, New York.
- [13] Frank P. M., 1993. Robust model based fault detection in dynamic systems. *On line fault detection and supervision in the chemical process industries*. pp.1-13. Pergamon Press. Oxford. IFAC Symposium series Number 1.
- [14] Frank P. M., 1990. Fault diagnosis in dynamic systems using analytical and knowledge based redundancy.- A survey and some new results. *Automatica*, 26:459-474.
- [15] Gertler. J. J. 1998. *Fault Detection and Diagnosis in Engineering Systems*. Marcel Decker, Inc. New York.
- [16] Hodouin D. And Makni 1996. S. Real time reconciliation of mineral processing plant data using bilinear material balance equations coupled to empirical dynamic models. *Int. Journal of Mineral Processing*, 48: pp. 245-264.
- [17] Isserman R 1998. Process Fault Detection based on modelling and estimation methods.: A survey. *Automatica*, 20: 387-404.
- [18] Isserman R 1993. Fault diagnosis of machines via parameter estimation and knowledge processing.-Tutorial paper. *Automatica*, 29: pp. 815-835.
- [19] Jackson J. E., 1956. Quality control methods for two related variables. *Industrial Quality Control*, 7:2-6,
- [20] Jackson J. E., 1959. Quality control methods for several related variables. *Technometrics*. 1:359-377.
- [21] Kramer M. A and Palowitch J.B.L. 1987. A rule-based approach to fault diagnosis using the signed direct graph. *AIChE. Journal*. 37: pp.1067-1078
- [22] Kramer M. A. and Finch F. E. 1988. Development and classification of expert systems for chemical process fault diagnosis. *Robotics and Computer integrated Manufacturing*. 4: pp 437-446
- [23] Lee G. et all.1999. Multiple-fault diagnosis under uncertain conditions by the quantification of qualitative relations. *Ind. Eng. Che.Res.*, 38: pp988-998.
- [24] Li. T. 1989. Expert Systems for Engineering Diagnosis: Styles, requirements for tools, and adaptability. Ed Tzafestas S. G. *Knowledge-based Systems Diagnosis, Supervision, and Control*, pp. 27-37. Plenum Press, New York
- [25] MacGregor J. F., 1994. Statistical Process Control of multivariate processes. *Proc. Of the IFAC Int. Symp. On Advanced Control of Chemical Processes*, pp 427-435, New York. Pergamon Press.
- [26] Mehra R. K. And Peschon J. 1971. An Innovation approach to fault detection and diagnosis in dynamic systems. *Automatica*, 7: pp. 637-640
- [27] Mironovski L. A. 1979. Functional diagnosis of linear dynamic systems. *Automation and Remote Control*, 40: 1198-1205.
- [28] Mironovski L. A. 1980. Functional diagnosis of linear dynamic systems- A survey. *Automation and Remote Control*, 41: 1122-1142
- [29] Mo K. J. et all. 1998. Robust fault diagnosis based on clustered symptom trees. *Control Engineering Practice*, 5: pp199-208
- [30] Mo K. J. et all. 1997. Development of operation-aided system for chemical processes. *Expert Systems with Applications*. 12: pp 455-464
- [31] Nekovie, R., and Sun, Y., (1995). Back propagation Network and its Configuration for Blood Vessel Detection in Angiograms, *IEEE Trans. on Neural Networks*, Vol 6, No 1.
- [32] Piovoso M. J. and Kosanovich K. A. 1994. Applications of multivariate statistical methods to process monitoring and controller design. *Int. Journal of Control*, 59:743-765
- [33] Piovoso M. J. and Kosanovich K. A. 1992. Monitoring process performance in real time. *Proc. Of the American Control Conference*, pp. 2359-2363, Piscataway, New Jersey. IEEE Press.
- [34] Wise B. M. And Gallagher N. B. 1996. The process chemometrics approach to process monitoring and fault detection. *Journal of Process Control*, 6:329-348

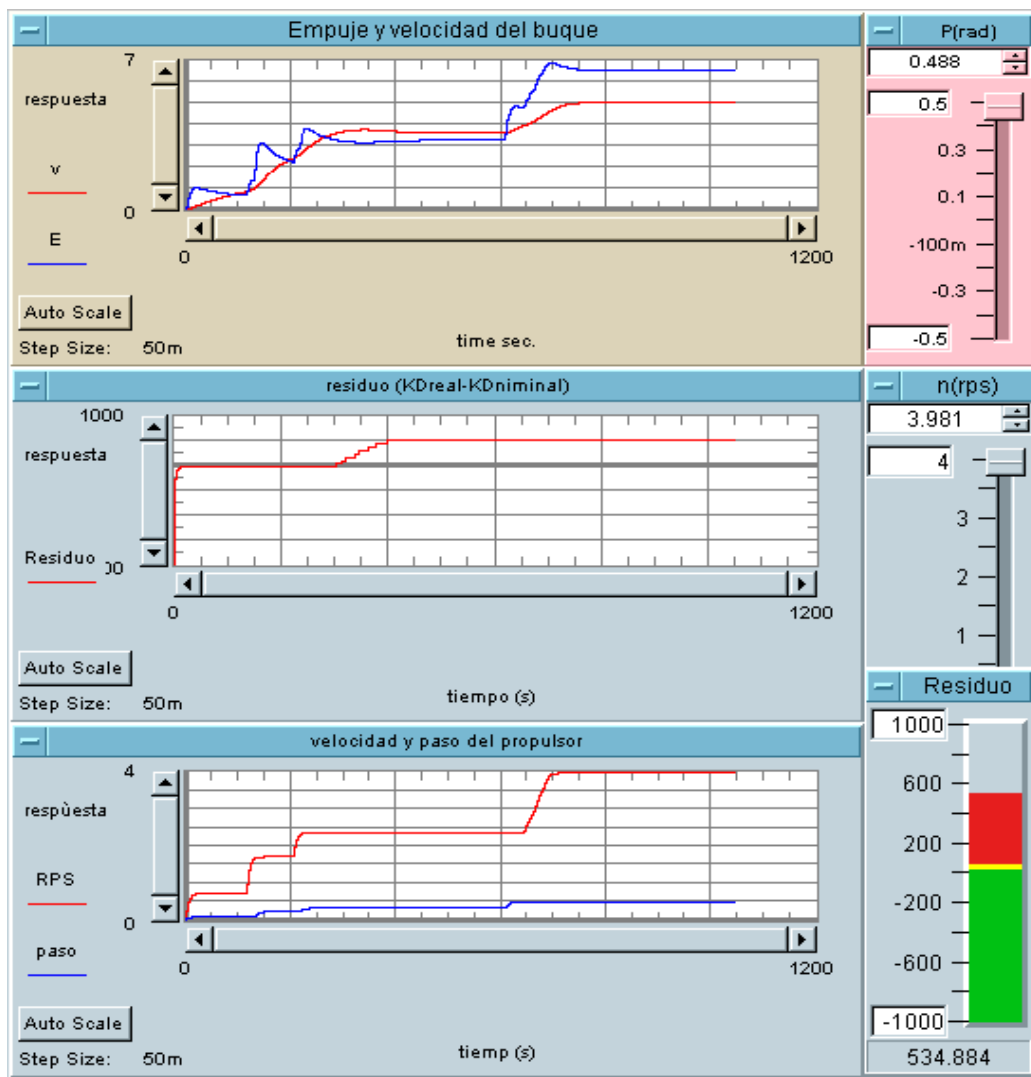


Fig. 7. Resultados obtenidos de un buque propulsado mediante hélice de paso controlable