

Actividades en Control y Supervisión Inteligente del Grupo de Sistemas Avanzados de Control (SAC) de la Universitat Politècnica de Catalunya (UPC)

Joseba Quevedo*, Vicenç Puig*, Teresa Escobet*, Ramon Perez*, Xavier Prats* y Claudia Maria Garcia*

*Grupo de investigación Sistemas Avanzados de Control (SAC)
Campus de Terrassa
Universitat Politècnica de Catalunya
Rambla S.Nebridi, 10. 08222 Terrassa, Barcelona, España
(e-mail: joseba.quevedo@upc.edu)

Resumen: En esta ponencia se presenta un resumen de las actividades de investigación que se están desarrollando en el grupo de “Sistemas Avanzados de Control” (SAC) de la Universidad Politécnica de Catalunya UPC en el Campus de Terrassa con especial énfasis en el campo del control y la supervisión inteligente. Para ilustrar esta actividad se presentarán tres aplicaciones reales que pueden tener gran interés social y económico. Copyright © XXXX CEA.

Palabras Clave: control inteligente, supervisión, detección de fallos, diagnóstico de fallos, molestia acústica, turbinas a gas, motores eléctricos.

1. INTRODUCCIÓN

El grupo de investigación Sistemas Avanzados de Control del Campus de Terrassa de la Universitat Politècnica de Catalunya está formado actualmente por 33 investigadores: 15 doctores y 18 doctorandos. Su actividad de investigación se estructura en el entorno de las siguientes temáticas:

- **Modelización, Identificación y Simulación de Sistemas Inciertos** descritos con modelos que incorporan la incertidumbre en la modelización mediante intervalos en los parámetros. Estos modelos son de mucha utilidad en el control robusto y en la detección robusta de fallos, entre otras. La simulación de los mismos requiere el desarrollo de simuladores, denominados intervalares, que sean capaces de simular el peor caso de todo el conjunto de componentes posibles contenidos en el modelo intervalar.
- **Control Avanzado** con controladores de tipo
 - **Robusto** haciendo uso de los modelos intervalares que incorporan la incertidumbre sobre la dinámica del proceso a controlar. El controlador que se obtenga deberá garantizar estabilidad y/o prestaciones de funcionamiento para todos los comportamientos dinámicos del proceso contenidos en el modelo.
 - **Óptimo/Predictivo** para problemas de gran dimensión en donde existen multitud de variables a controlar así como multitud de variables de control con fuerte interacción entre ellas, como por ejemplo: redes de distribución de agua, aguas residuales, ...
 - **Inteligente** mediante la aplicación de técnicas de control borroso y redes neuronales para alcanzar las prestaciones de funcionamiento de sistemas dinámicos inciertos, sujetos a perturbaciones e inestables, como es el caso del control autónomo de helicópteros, control activo de ruido,...
- **Supervisión y Diagnóstico de Fallos en Procesos Industriales** mediante sistemas informáticos y algoritmos que permitan en tiempo real supervisar y diagnosticar fallos,

ya sea utilizando modelos cuantitativos y semi-cuantitativos (intervalares) de proceso industrial a supervisar o diagnosticar, ya sea empleando técnicas de análisis y reconocimiento de señales y eventos.

- **Control Tolerante a Fallos** mediante el desarrollo de sistemas de control que sean capaces de funcionar tras la aparición de fallos en sensores y/o actuadores, o bien, en componentes del propio sistema mediante la activación de acciones correctoras una vez el fallo ha sido detectado, aislado y se haya identificado su magnitud.
- **Aplicación de las herramientas de optimización y satisfacción de restricciones al control, de técnicas de sistemas híbridos.** Muchos de los problemas de control, identificación, supervisión y organización de procesos industriales pueden traducirse a un problema de optimización y/o satisfacción de restricciones y pueden representarse como sistemas híbridos con diversos modos de funcionamiento (normal o en fallo). La resolución de estos problemas se realiza mediante la utilización de herramientas de optimización y/o satisfacción de restricciones y técnicas de sistemas híbridos que permite obtener soluciones locales y/o globales.

A continuación, se presentaran tres ejemplos de aplicación real de las actividades que desarrolla el grupo SAC en el área del control y la supervisión inteligente

2. DIAGNÓSTICO EN TIEMPO REAL DE TURBINAS A GAS BASADA EN MODELOS INTERVALARES

Como ejemplo de una aplicación real de monitorización y diagnóstico de fallos inteligente de un sistema, se presenta un resumen de la patente de EEUU nº 6157310 en la cual tanto el grupo SAC de la UPC como el grupo CISCO del LAAS de Toulouse coordinados por L. Travé han participado en este trabajo. Se trata de una patente americana sobre diagnóstico de fallos de turbinas a gas que proporciona un sistema de monitorización de la operación de sistemas dinámicos,

especialmente para turbinas a gas aunque puede ser aplicada a otros sistemas. A partir del procesamiento de las señales eléctricas proporcionadas por los sensores del proceso, el sistema es capaz de producir una pluralidad de señales que indican anomalías diferentes.

El procesamiento automático consiste en comparar los valores instantáneos de algunas de las variables medidas con unos límites almacenados en memoria a partir de la respuesta estimada por modelos matemáticos intervalares produciendo señales de anomalías si las variables medidas superan sus límites de funcionamiento normal. El sistema de monitorización (figura1) también indica el estado actual del sistema y las prestaciones que proporciona en cada momento, de forma que si las prestaciones se alejan de los valores esperados se produce un síntoma de anomalía que es analizado por el módulo de diagnóstico de fallos.

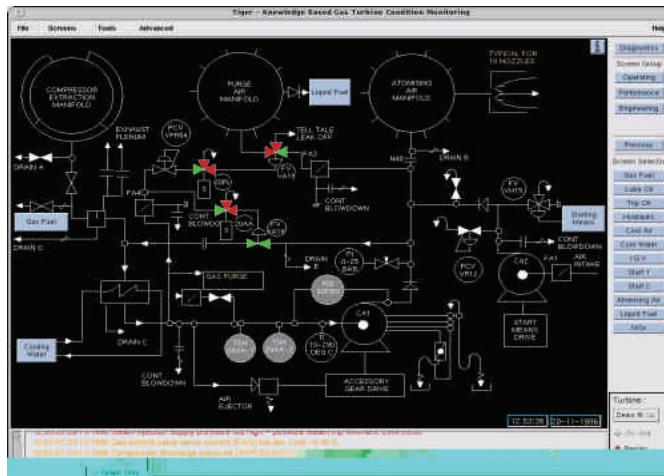


Figura 1. Monitorización de la turbina de gas

El módulo de diagnóstico de fallos (figura 2) realiza un análisis sobre el origen del fallo a partir de las señales de anomalías almacenadas y proporciona de forma precoz su resultado como señales de los fallos producidos mediante un mensaje en el sistema de monitorización.

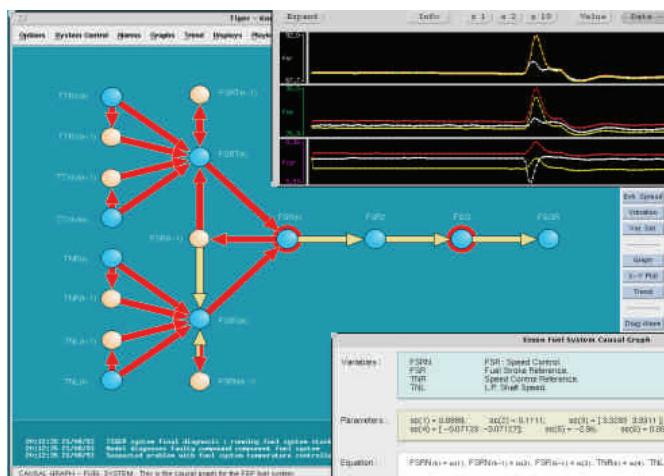


Figura 2. Sistema de diagnóstico de la turbina

Este sistema de diagnóstico inteligente se basa en la utilización de grafos causales para determinar las dependencias entre componentes (figura 2) y el uso de modelos intervalares. El razonamiento causal se refiere al análisis del comportamiento de

un sistema en relaciones de causa-efecto entre entidades, por ejemplo variables o alarmas.

Una estructura causal es una descripción abstracta de la influencia que tiene una variable sobre otras (Montmain & Gentil, 1999). El comportamiento de un dispositivo puede parcialmente describirse mediante un grafo causal el cual represente directamente la relación funcional entre variables o conceptos más complejos (síntomas o fallos). Las variables se relacionan mediante arcos: $x \rightarrow y$, significa que la variable y en el instante t depende de la variable x ; x es la causa, y es el efecto. En un grafo, el análisis hacia delante y hacia atrás, permiten determinar las relaciones causa-efecto.

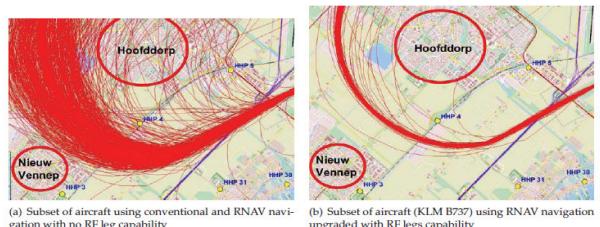
Desde el punto de vista práctico, la construcción de un grafo causal no es necesariamente una tarea fácil, se requiere un análisis físico detallado del sistema, pero esto, a su vez, es la fuente de su capacidad explicativa. Las soluciones al diagnóstico de fallos que provienen del área inteligencia artificial utilizan los grafos para modelizar los sistemas.

La forma de representar un grafo es mediante nodos y arcos. Los nodos representan las variables y los arcos representan las relaciones causales entre ellas. El principio implícito es que esta estructura constituye un instrumento conceptual para razonar acerca de la forma en que los cambios normales y los anormales se propagan por la planta o como pueden ser explicados; este principio es válido siempre que las relaciones causales no se vean modificadas a causa de los fallos.

El diagnóstico basado en grafos causales tiene el mismo principio básico. Tiene por objetivo explicar el motivo de las desviaciones detectadas en la evolución de las variables de una planta proporcionando los mínimos casos de malfuncionamiento posibles. Si se detectan desviaciones importantes, se comprueba para cada posible fallo si es capaz de explicar el malfuncionamiento, sea por un cambió directo en una de las variables o por su propagación a través del sistema. El grafo es utilizado, mediante un algoritmo adelante-atrás, para detectar fallos: la búsqueda hacia atrás permite formular hipótesis y hacia delante permite su evaluación. La figura 2 presenta un grafo causal del subsistema de una turbina a gas.

3. TRAYECTORIAS DE AVIONES EN AEROPUERTOS PARA MINIMIZAR LA MOLESTIA ACÚSTICA

El problema real de la molestia acústica en la población por las operaciones de despegue y aterrizaje de aviones en aeropuertos urbanos (figura 3) es un repto al que se dedica mucho esfuerzo técnico-científico y medios económicos para resolverlo. Es cierto que el ruido producido por los aviones se ha reducido sustancialmente con el desarrollo de nuevos motores más silenciosos y al diseño de las aeronaves más eficientes aerodinámicamente y menos propagadoras del ruido acústico. Sin embargo queda mucho trabajo por hacer en el cálculo de las trayectorias de despegue y aterrizaje de los aviones.



(a) Subset of aircraft using conventional and RNAV navigation with no RF leg capability
(b) Subset of aircraft (KLM B737) using RNAV navigation upgraded with RF legs capability

Figure II-3: Example of flight tracks corresponding to the initial turn of the Spijkboor departure in Schiphol (The Netherlands)

Courtesy of Theo van de Ven, KLM. Printed with permission

Figura 3. Ejemplo de las trayectorias de despegue de aviones en un aeropuerto

Una aportación del grupo SAC en esta temática ha sido la tesis doctoral de Xavier Prats (Prats, 2009) que ha planteado el siguiente esquema (figura 4) para resolver este problema. Y uno de los temas abordados ha sido la modelización cualitativa mediante lógica borrosa de la molestia acústica que posteriormente es utilizada como una no linealidad de la función objetivo a minimizar al diseñar las trayectorias de despegue de los aviones.

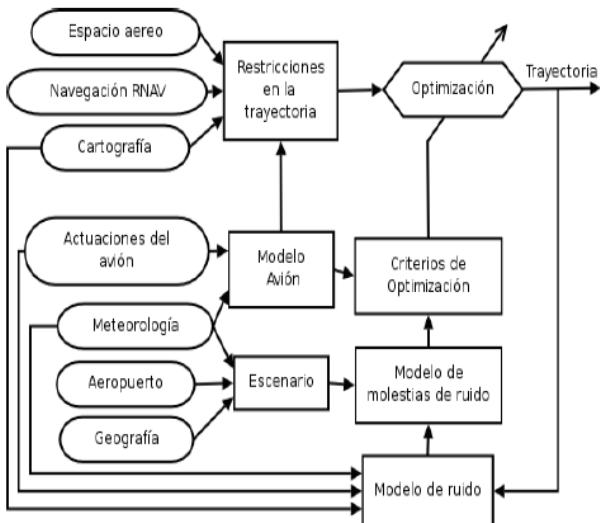


Figura 4. Esquema general en la optimización de trayectorias

Todas las medidas y escalas métricas del ruido pretenden modelar cómo el sonido es percibido por los humanos. Sin embargo estas medidas no definen suficientemente las molestias causadas por un ruido en particular. Las molestias o percepción de un ruido acústico define la relación entre una situación acústica dada y un individuo o conjunto de personas afectadas por el ruido y cómo lo evalúan desde un punto de vista cognitivo y emocional. Además de los elementos acústicos, como volumen, intensidad, distribución espectral y duración del ruido hay una lista de elementos no acústicos que deben tenerse en cuenta para definir la molestia acústica global.

Según varios estudios (SAE 86) se identifican los siguientes factores, además de los elementos acústicos, como relevantes en la percepción de los episodios de sonido:

- el ruido de fondo existente;
- la hora del día en que sucede el episodio (mañana, tarde, noche);
- el tipo de día en que sucede el episodio de ruido (laborable, fin de semana, periodo vacacional...);
- el intervalo de tiempo entre vuelos consecutivos;
- el tipo de zonas afectadas (rurales, residenciales, industriales, hospitales, escuelas, mercados...)
- elementos personales (estados de ánimo, aprehensión e irritabilidad frente al ruido, salud, tamaño de la familia...); y
- aspectos socio-económicos (edad, hábitos, nivel económico, nivel cultural,...).

3.1. Razonamiento cognitivo y conjuntos borrosos

La molestia es un hecho subjetivo complejo y depende del contexto. En este trabajo se propone modelar las molestias

producidas por el ruido de un aeroplano usando la teoría borrosos. Brevemente, los conjuntos borrosos son conjuntos cuyos elementos tienen un grado de pertenencia en lugar de la clásica noción binaria de pertenencia expresada como que un elemento pertenece o no a un conjunto. De esta forma, las afirmaciones pueden ser presentadas con distintos grados de certeza o falsedad. Mientras que las variables matemáticas toman valores numéricos, en aplicaciones de lógica borrosa se usan variables lingüísticas no numéricas para facilitar la expresión de reglas y hechos. Así pues, la lógica multi-valuada se puede extender para permitir que premisas borrasas aporten conclusiones con diferentes gradaciones. Sistemas basados en reglas son usados en inteligencia artificial para realizar predicciones basadas en conocimientos de expertos y razonamiento clásico. Un modelo basado en reglas borrosas extiende la lógica clásica y su razonamiento a variables suaves. Un típico ejemplo de estas cantidades borrasas es el nivel de molestia por ruido expresada en una palabra: un *término lingüístico*. En este sentido, las reglas borrasas presentan la ventaja de permitir una gestión adecuada del conocimiento vago e incierto siendo más comprensible para los humanos.

3.2. Modelo borroso simple para molestias de ruido

Esencialmente la componente de molestia puede verse como una caja negra que produce como salida el grado de molestia, generada a partir de los datos de entrada por un mecanismo de inferencia. Internamente el dominio específico de la inteligencia combina una base de datos y una base de conocimientos. Esta base de conocimiento puede proceder de múltiples fuentes, como resultado de un estudio detallado por expertos en molestias por ruido, datos tratados provenientes de estudios sociológicos, o idealmente como la combinación de ambos. Seguidamente se describe un modelo simple de las molestias usando el razonamiento borroso. Las funciones no lineales de las molestias derivadas de él se usarán como funciones objetivo para la optimización y el diseño de procedimientos óptimos de disminución del ruido.

3.2.1. Variables de entrada y salida

En este modelo simple las molestias generadas por la trayectoria de un aeroplano se calculará a partir de tres entradas que son:

- el nivel de ruido, en función del máximo nivel de sonido (L_{max}) métrico
- el periodo del día en que el procedimiento se supone que se desarrollará, en función de la hora del día; y
- el tipo de zona que sobrevolará, en función de la actividad que se desarrolla en la zona.

Por otro lado sólo se usará una variable de salida:

- la molestia que se derivará expresada en una variable de salida numérica: un Índice de Molestia Normalizada (NAI).

3.2.2. Fuzzificación, base de reglas y defuzzificación

Tras la definición de todas las entradas/salidas del sistema borroso se puede establecer una base de reglas para representar las molestias de un episodio particular en forma de reglas IF/THEN. Se propone un método simple de establecer la base de reglas. Una Zona Residencial por la tarde es seleccionado como un escenario en que un ruido Muy Alto produce una molestia Extrema, un ruido Alto una molestia Alta, ruido Medio corresponde a molestia Moderada, ruido Bajo molestia Pequeña y ruido Muy Bajo o Nulo una molestia Nula. En otras palabras esto se expresaría con las siguientes reglas:

IF [Type of Zone IS Residential Zone AND Period of Day IS Afternoon AND Noise Level
 IS Very High] THEN Annoyance IS Extreme
 IF [Type of Zone IS Residential Zone AND Period of Day IS Afternoon AND Noise Level
 IS High] THEN Annoyance IS High
 IF [Type of Zone IS Residential Zone AND Period of Day IS Afternoon AND Noise Level
 IS Medium] THEN Annoyance IS Moderated
 IF [Type of Zone IS Residential Zone AND Period of Day IS Afternoon AND Noise Level
 IS Low] THEN Annoyance IS Small
 IF [Type of Zone IS Residential Zone AND Period of Day IS Afternoon AND Noise Level
 IS (Very Low OR Null)] THEN Annoyance IS Null

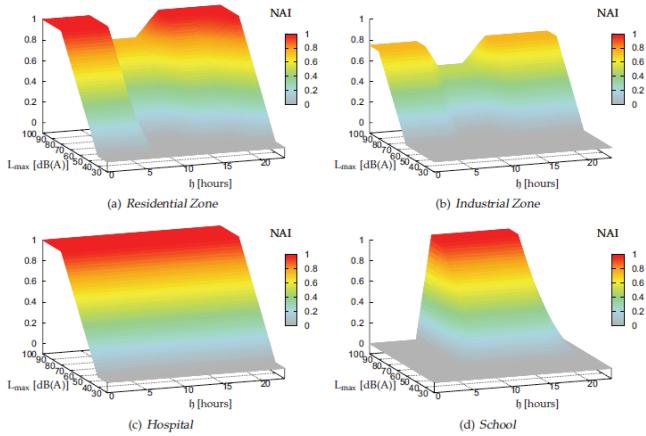


Figura 5 Representación del Índice de Molestia Normalizado (NAI) como función de las variables de entrada

Tras un proceso de defuzzificación se pueden calcular un conjunto de *funciones de molestia* no lineales $A(L_i(t), h) : R^2 \rightarrow R$ relacionando un nivel de ruido máximo $L_i(t)$, para un lugar i a la hora h , con un valor del Índice de Molestia Normalizada. La figura 5 muestra gráficamente estas funciones para cuatro tipos de zonas habitadas consideradas en este trabajo. Finalmente para una hora del día determinada, se desarrolla una aproximación polinomial de cuarto orden del Índice de Molestia del Ruido en función del nivel máximo de sonido A-ponderado. Esta nueva función, $A(L_i(t)) : R \rightarrow R$, es la que se usa como función objetivo en el proceso de optimización de las trayectorias. La figura 6 muestra un par de ejemplos de este ajuste polinomial simple que permite evitar la forma triangular de las originales con los problemas que conlleva el no ser diferenciables.

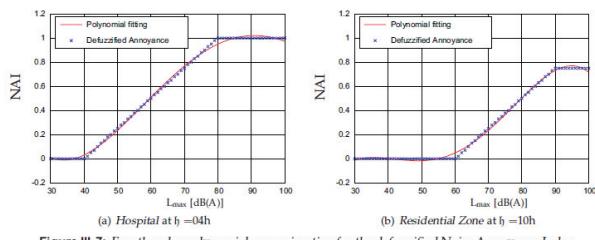


Figura 6. Ajuste polinomial de la salida del modelo borroso

Los siguientes gráficos (figura 7) presentan unos resultados satisfactorios de este trabajo en un aeropuerto real, el aeropuerto de Girona.

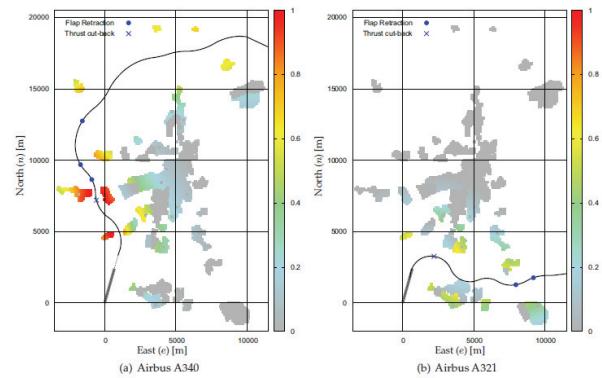
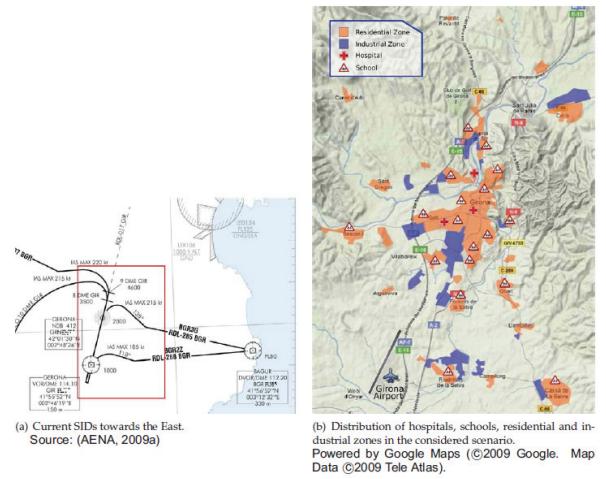


Figura 7. Resultados de trayectorias en el aeropuerto de Girona

4. PROGNOSTICO Y MANTENIMIENTO PREDICTIVO INTELIGENTE DEL DETERIORAMIENTO DE SISTEMAS MOTORIZADOS

En la actualidad la monitorización de la salud de cualquier sistema dinámico industrial, es una de las claves para aumentar la disponibilidad, fiabilidad y seguridad de los sistemas y procesos industriales. Concretamente, el pronóstico y la ayuda al mantenimiento, conocido con las siglas PHM (Prognosis and health management), es uno de los procedimientos más comúnmente utilizados para la monitorización de la salud. Las herramientas PHM permiten cuantificar el grado de desviación o la degradación de las condiciones de funcionamiento normal previstas. El grupo SAC está trabajando en la implementación de una estructura PHM en tiempo real, los primeros resultados en este tema se muestran en la ponencia presentada en la conferencia anual de la sociedad de pronóstico y ayuda al mantenimiento 2010, (García et al, 2010). La estrategia para llevar a cabo la estructura PHM se basa en una serie de pasos consecutivos visualizados en la figura 8.

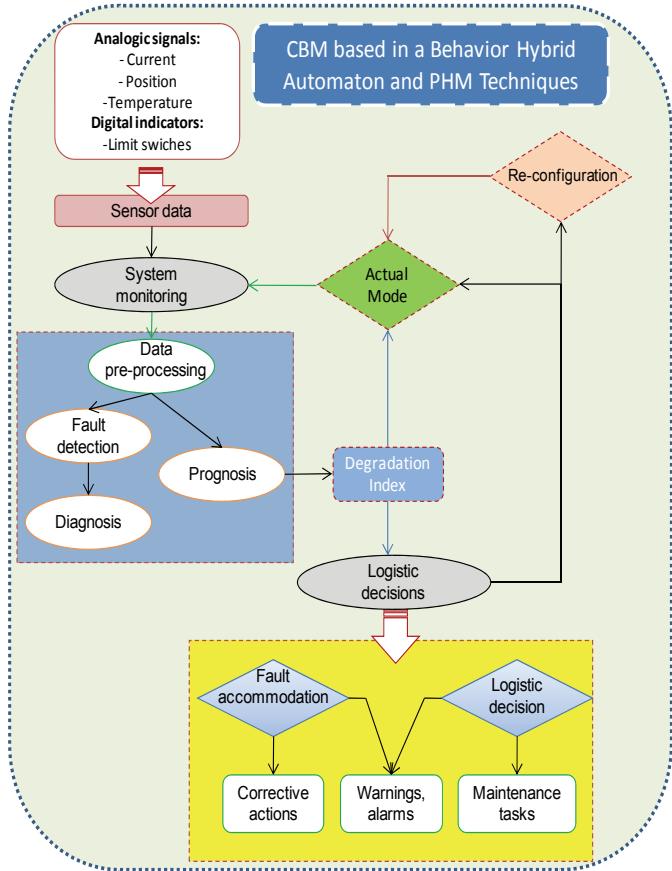


Fig. 8. Estructura PHM

La estructura propuesta incluye tanto la parte de diagnóstico como la pronóstica y consta de las siguientes etapas: (1) adquisición de datos, (2) monitorización de las variables medidas; (3) procesado de datos; (4) diagnóstico de fallos; (5) pronóstico; y, (6) decisiones acerca de las tareas de mantenimiento y/o acciones correctivas a realizar.

Desde el punto de vista de ingeniería, las técnicas pronósticas y diagnósticas de fallos se pueden clasificar en tres categorías: basadas en la experiencia, basadas en modelos y basadas en señales (Tran et al., 2009).

Las técnicas basadas en el análisis de señales incluyen desde métodos estadísticos a las técnicas de aprendizaje automático o aprendizaje inteligente. A menudo, el pronóstico se caracteriza mediante la estimación de la vida útil restante (RUL) de los componentes o sistema (Sheppard et al., 2008). Por ejemplo en Tran et al., 2009 se utiliza una red neuronal adaptativa con parámetros difusos (ANFIS) para realizar el pronóstico estado de la máquina. En (Kalgren et al., 2006) se propone monitorizar el RUL mediante un índice de salud caracterizado como una escala de grises al que denomina *grey-scale Health Index* (HI), y consiste en un variable continua en el rango de 0 (totalmente operable) y 1 (sistema averiado).

En la aplicación que se ha desarrollado, se utiliza una ANFIS para predecir el índice de salud (HI). Se ha utilizado un proceso que repetitivamente realiza una tarea a largo de un periodo de tiempo denominado ciclo, concretamente se trata de una cinta transportadora gobernada por un motor CA que desplaza un carro móvil entre dos brazos robotizados.

Para monitorizar el comportamiento del conjunto se dispone de un sensor de temperatura (T_M) ubicado en la carcasa del motor y

un sensor de corriente (I_M) del cual se extrae la amplitud (A_I) y la frecuencia (F_I). A partir de la información proporcionada por el encoder, se calcula la velocidad del carro (V).

Para predecir el estado del sistema se ha utilizado una ANFIS con la estructura mostrada en la figura 9, la cual consta de un conjunto difuso de reglas tipo Takagi-Sugeno (FIS), permitiendo la introducción de conocimiento experto, y una red neuronal (NN) adaptativa.

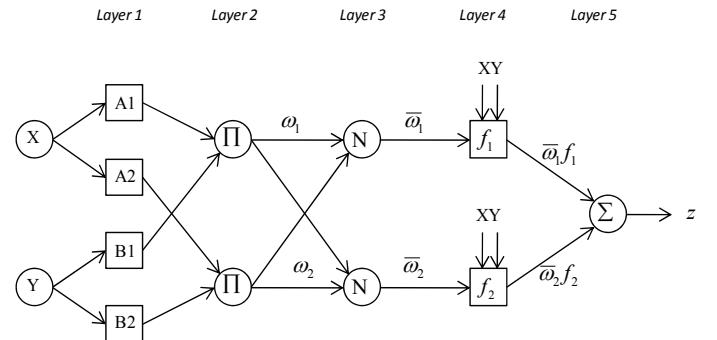


Figure 9. Estructura de una ANFIS con dos variables entrada

En el caso que nos ocupa, las variables de entrada al ANFIS son: V , T , A_I i F_I , para cada una de las dos direcciones de desplazamiento de la cinta. Para el aprendizaje y la validación de ANFIS se han realizado una serie de escenarios en los que ha forzado un comportamiento degradado del sistema, incrementando la fricción entre la cinta y la estructura. La figura 10 muestra los resultados de la ANFIS, en un primer escenario se dispone de 300 ciclos con una fricción media y en el segundo escenario se dispone de 550 ciclos con una fricción alta.

En la figura 10 se muestra la predicción el índice de degradación del sistema (HI). Este índice se ha codificado de 1 a 5 para obtener el denominado número de condición del sistema (SC), el cual nos indica después de n ciclos de funcionamiento cual es el estado de degradación del sistema. Dicho índice enlaza con la propuesta de Kalgren et al. (2006), representada en la Tabla 1 y tiene como objetivo final la de proporcionar al ingeniero de planta información acerca de la capacidad operativa del sistema e indicar cuáles deben ser las tareas de mantenimiento o acciones logísticas a realizar.

Tabla 1. Capacidad operativa en función del grado de degradación del sistema

CC	Operational Capability	Maintenance Action	Logistics Action
1	Fully Functional	No Maintenance Required	No Logistic Changes
2	Functional with degraded Performance	Maintenance at Convenience	Trigger Opportunistic Logistic Sparing
3	Reduced Functionality	Schedule Maintenance Now	On-Demand Logistic Sparing
4	Functionality Severely Impinged	Remove from Service ASAP	Logistic Emergency Sparing
5	No functionality	Remove from Service Now	Logistic reflect unit out of Service

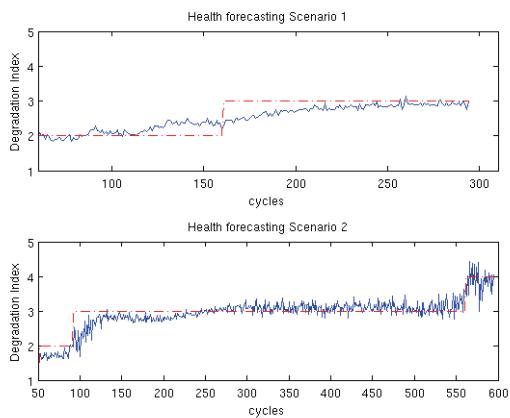


Figura 10. Predicción de la salud del sistema

5. CONCLUSIÓN

Este artículo presenta una visión representativa de la notable actividad del grupo de investigación Sistemas Avanzados de Control(SAC) de la UPC en el campo del control y la supervisión inteligente. En particular, se han descritos tres aplicaciones de interés en este campo.

El primero ha presentado la supervisión inteligente de turbinas a gas que son procesos complejos que trabajan de forma ininterrumpidamente durante meses sin parar y por ello se necesita un sistema de supervisión que detecte y diagnostique posibles fallos en tiempo real, analice el origen de los fallos y su posible solución (recuperación o parada de la turbina). Para llevar a cabo esta supervisión se han utilizado modelos intervalares y grafos causales de forma muy satisfactoria que ha dado lugar a una patente internacional.

El segundo ejemplo ha estudiado un problema real aun no resuelto como es la determinación óptima de las trayectorias de los aviones en un aeropuerto urbano para minimizar la molestia acústica en zonas urbanas cercanas a los aeropuertos. En este caso mediante lógica borrosa se ha modelado de forma cualitativa la molestia acústica de los aviones en las personas en diferentes lugares y horas del día.

Finalmente, la tercera aplicación ha tratado del importante problema de la utilización de técnicas de prognosis del estado de maquinas eléctricas para su mantenimiento predictivo que permite realizar acciones o sustituciones de subsistemas, actuadores o sensores antes de que se produzcan fallos progresivos debido a la fatiga del mismo. Para la prognosis se ha utilizado una red neuronal que estima el estado futuro del sistema.

Los resultados positivos obtenidos en estas aplicaciones nos permiten augurar un futuro importante de estas técnicas inteligentes para estas y nuevas aplicaciones de control y supervisión de sistemas complejos.

6. AGRADECIMIENTOS

Los autores quieren expresar su agradecimiento al Ministerio de Ciencia y Tecnología por la financiación recibida a través del proyecto CICYT HYFA referencia 2008-01996 y a la Generalitat de Cataluña por el reconocimiento de SAC de la UPC como grupo de investigación consolidado.

7. REFERENCIAS

Garcia, C.M., Escobet, T. y Quevedo J. (2010) *PHM Techniques for Condition-Based Maintenance Based in Hybrid System Model Representation*. Annual Conference of the Prognostic and Health Management Society, 2010.

Kalgren, P.W., Byington, C.S., P.E., Roemer M.J., Watson, M.J. (2006). *Defining PHM, a lexical evolution of maintenance and logistics*. IEEE AUTOTESTCON.Anaheim, California, pag. 353-358.

Milne R. y Nicol C. (2000). United States Patent 6157310 con la colaboración de los grupos de investigación CISCO del LAAS de Toulouse y SAC (UPC) del Campus de Terrassa, <http://www.freepatentsonline.com/6157310.html>

Montmain J., Gentil S. (2000) *Dynamic causal model diagnostic reasoning for online technical process supervision*. *revista Automatica* vol. 36(8), pag. 1137-1152

Prats X. (2010). *Contributions to the Optimisation of Aircraft Noise Abatement Procedures*, tesis doctoral, UPC.

SAE – COMITEE A-21, AIRCRAFT NOISE (1986). Procedure for the calculation of airplane noise in vicinity of airports. *Tech. rept. Society of Automotive Engineers*, Warrendale, PA (USA). Aerospace Information, Report (AIR) No. 1845. 32

Sheppard, J.W., Wilmering,T.J, Kaufman, M.A.(2008). *IEEE Standards for Prognostics and Health Management*. Simposio IEEE AUTOTESTCON Anaheim, California, pag. 243-248.

Tran, V.T., Yang, B.S. and Tan, A.C.C. (2009). Multi-step ahead direct prediction for machine condition prognosis using regression trees and neuro-fuzzy systems. *Revista Expert Systems with Applications*, vol. 36, pag. 9378–9387.