

# Ca~En: un sistema basado en modelos cualitativos para el diagnóstico de fallos en sistemas dinámicos

Louise Travé-Massuyès\*, Teresa Escobet†, Sebastián Tornil†, Joseba Quevedo†

\*LAAS-CNRS y LEA-SICA  
7 avenue du Colonel Roche  
31077 Toulouse, Francia  
[{louise}@laas.fr](mailto:{louise}@laas.fr)

†UPC y LEA-SICA  
Departamento de control automático  
Rambla Sant Nebridi, 10  
08222 Terrassa, España  
[{teresa,stornil,joseba}@esaui.upc.es](mailto:{teresa,stornil,joseba}@esaui.upc.es)

## 1 Introducción

Las tecnologías de razonamiento cualitativo y basadas en modelos han demostrado ser útiles en la resolución de problemas realmente complicados (Struss *et al.*, 2000) (Travé-Massuyès y Milne, 1997). Actualmente existen ya en el mercado diversos productos y sistemas y ya se han presentado muchos prototipos avanzados relacionados con el tema (MONET-ILC, 1998) (Cauvin *et al.*, 1998). También, se han identificado claramente los espacios que separan la investigación de la industria, lo cual debería contribuir a acercar estos dos campos progresivamente (Travé-Massuyès y Milne, 1998).

El diagnóstico ha sido el campo principal de la aplicación de las tecnologías de razonamiento cualitativo y basadas en modelos, logrando importantes ventajas a partir de dos ideas clave principales: la primera es la representación por separado de los conocimientos de procesos y los conocimientos de tareas, y la segunda es la representación de los conocimientos de procesos en un nivel suficiente de abstracción.

A pesar de que basar el razonamiento en un modelo comporta muchas ventajas, ello enfatiza el papel principal del proceso de modelado. En realidad, modelar cualquier sistema es una tarea compleja que nunca resulta fácil. Todavía no tenemos las herramientas para la creación de modelos automatizados y hoy en día el modelado es con frecuencia un proceso manual y especializado. Sin embargo, en los últimos años ha merecido mucha atención un aspecto del modelado automatizado que consiste en transformar un modelo con un formato determinado en otro formato más apropiado para resolver la tarea en cuestión. Por ejemplo, las técnicas de ordenación causal permiten derivar la estructura causal de un modelo determinado a partir de un conjunto de ecuaciones algebraicas y diferenciales (Iwasaki and Simon, 1994) (Travé-Massuyès and Pons, 1997). La estructura causal es, por lo tanto, de gran valor para fines explicativos y de diagnóstico. Otro ejemplo es el de haber demostrado que pueden utilizarse modelos de autómatas para generar estados que representen situaciones erróneas o normales (Bibas *et al.*, 1996), y estos estados pueden utilizarse como referencia en un enfoque de reconocimiento de situaciones (Dousson *et al.*, 1993).

La metodología de modelado del sistema Ca~En aprovecha los métodos de modelado automático (Travé-Massuyès y Pons, 1997). En este documento, se presentan todos los pasos del método de modelado: la generación automática de una estructura causal a partir de un modelo de ecuaciones orientado a los componentes, cómo obtener los parámetros de las influencias causales y cómo derivar automáticamente los modelos operacionales de detección. El método se aplica al sistema de combustible de una turbina de gas modelo Frame 6 de General Electric. Parte de este trabajo se efectuó en el marco de los proyectos europeos TIGER y TIGER-SHEBA.

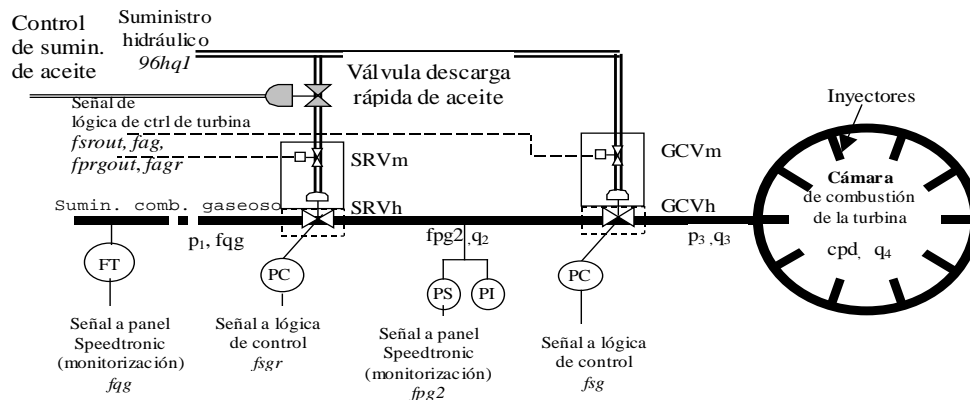
## 2 El sistema de alimentación (GFS) de una turbina a gas Frame 6

### 2.1 Descripción

El sistema de control de turbinas de gas controla la velocidad del eje modificando la referencia del flujo de combustible, que en operación normal es gas natural. Por ello, una de las partes críticas de la turbina es el subsistema de alimentación de combustible, conocido como GFS (*Gas Fuel System*). De hecho, el rendimiento y eficacia de la turbina depende ampliamente del control preciso de la entrada de combustible y ésta es precisamente la tarea del GFS.

Los componentes principales del GFS de una turbina Frame 6 son dos actuadores: la válvula SRV (*Stop Ratio Valve*) y la válvula GCV (*Gas Control Valve*). Estas válvulas están conectadas en serie y controlan el flujo del combustible que entra en las cámaras de combustión. La primera de estas válvulas, la SRV, tiene por objetivo mantener la presión entre válvulas constante. Al mantenerse la presión constante, el flujo del combustible se determina simplemente a partir de la posición de la GCV.

En la Figura 1 se muestran las válvulas SRV y GCV con su sistema de control. Ambas válvulas han sido analizadas desde el punto de vista hidráulico (h) y mecánico (m). El primero incluye el asiento de la válvula y componentes relacionados que determinan el flujo de combustible a través de la válvula y el segundo incluye todos los componentes que controlan la posición de la válvula, es decir, todos los componentes mecánicos de la válvula (diafragma, muelle, ...), servomotor neumático, controlador del suministro de aceite y controlador de la posición de la válvula.



**Figura 1.** Diagrama de flujo del GFS de la turbina Frame 6 de GE.

La descripción de las variables relevantes que aparecen en la figura anterior queda recogida en la tabla 1. De igual modo, la descripción de los componentes que aparecen en las especificaciones de diagnóstico realizadas por el usuario quedan recogidas en la tabla 2.

$96hq1$	Presión de alimentación del sistema hidráulico
$Fprgout$	Referencia de presión a la salida de la SRV
$Fsgr$	Posición de la SRV
$Fpg2$	Presión a la salida de la SRV
$Fsrout$	Referencia de posición de la GCV
$Fsg$	Posición de la GCV
$Cpd$	Presión de descarga del compresor

**Tabla 1.** Lista de variables del GFS.

SRVh	Subsistema hidraulico de la SRV
SRVm	Subsistema mecánico de la SRV
GCVh	Subsistema hidraulico de la GCV
GCVm	Subsistema macánico de la GCV
Injct	Inyectores de las cámaras de combustión

Tfsgr	Sensor de posición de la válvula SRV
Tfsg	Sensor de posición de la válvula GCV
Tfqg	Sensor de flujo de combustible
Tcpd	Sensor de presión de descarga del compresor

**Tabla 2.** Lista de componentes del GFS

## 2.2 Modelo de ecuaciones orientado a los componentes del GFS

La tabla 3 inferior proporciona el modelo orientado a componentes del GFS. El comportamiento de cada componente se describe con un modelo genérico, (Travé-Massuyès y Escobet, 1995).

Sin perder la generalidad, las presiones en un punto de unión y los flujos en una derivación se han igualado y redominado como una sola variable utilizando la ecuación de igualdad de presiones de un modelo de puntos de unión y la ley de ecuaciones de equilibrio de flujos para cada componente, respectivamente.

Componente	Relación	Ecuación	Variables exógenas
Injt	r1	$q_3 = K_{inj}\sqrt{p_3 - cpd}$	cpd
	r2	$q_4 - Kl \times q_3 = 0$	
GCVh	r3	$q_2 = fsg\sqrt{fpg2 - p_3}$	
	r4	$q_3 - Kl \times q_2 = 0$	
SRVh	r5	$fqg = fsgr\sqrt{p_1 - fpg2}$	p1
	r6	$q_2 - Kl \times fqg = 0$	
GCVm	r7	$fsg = f(fag, 96hq1)$	96hq1
SRVm	r8	$fsgr = f(fagr, 96hq1)$	96hq1
GCVm	r9	$fsg = f(fsrou, 96hq1)$	fsrou, 96hq1
SRVm (SRVm +SRVh)	r10	$fsgr = f(fprgout, fpg2, 96hq1)$	fprgout 96hq1
	r11	$fpg2 = f(fprgout)$	

**Tabla 3.** Modelo orientado a componentes del GFS.

## 3 El sistema de diagnóstico Ca~En

Ca~En es un sistema de diagnóstico basado en modelos causales que incluye un módulo de detección de fallos y un módulo de aislamiento de fallos. El mecanismo de detección de fallos detecta discrepancias entre el comportamiento pronosticado por los modelos y el comportamiento observado en el sistema. Se basa en la utilización de modelos intervalares para generar umbrales adaptativos para las variables que indican cuando los valores de dichas variable pueden ser explicados por un comportamiento sin fallos del sistema y cuando no. El mecanismo de aislamiento de fallos entrelaza entonces las discrepancias obtenidas, el conjunto de variables cuyo valor sobrepasa el umbral correspondiente, para, utilizando un modelo causal temporal, obtener el componente o conjunto de componentes que presentan un fallo en su funcionamiento.

### 3.1 El formalismo de la representación de información del Ca~En

El formalismo del Ca~En representa el sistema físico en dos niveles de abstracción:

1. Un *nivel local* basado en modelos causales en el que los enlaces, denominados *influencias*, de dichos modelos representan relaciones de causalidad entre variables del sistema;

2. Un *nivel global* que permite manipular ecuaciones algebraicas y diferenciales que representan relaciones o restricciones que relacionan las variables.

Ambos niveles son capaces de gestionar informaciones imprecisas en forma de intervalos (rangos de valores). Un programa en Ca~En representa un modelo formal del sistema físico, creado a partir del conocimiento de las leyes físicas que rigen el comportamiento de dicho sistema.

En el nivel local, las influencias causales permiten la representación de información de dependencia causal. El formalismo Ca~En ofrece cinco tipos de influencias cuya forma interna se presenta más adelante:

- *1er orden dinámico*, representado por el símbolo —D1→ entre las variables que afectan y las variables afectadas;
- *2º orden dinámico*, representado por el símbolo —D2→;
- *integral*, representado por el símbolo —I→;
- *estático*, representado por el símbolo —S→;
- *constante*, representado por el símbolo —C→.

Las influencias causales se caracterizan por varios parámetros, como una ganancia, un retardo y un tiempo de respuesta para las influencias dinámicas de 1er orden. A todos los parámetros a excepción de los retardos puede asignárseles un determinado rango si no se conocen con exactitud o un valor real en caso contrario. También permiten una condición paramétrica que especifica las condiciones lógicas bajo las que está activa la influencia. Ésta es la clave para la representación de sistemas híbridos. Las influencias se etiquetan mediante sus componentes o procesos subyacentes.

El siguiente ejemplo de Ca~En expone que la variable GFS\_FQG2 se ve influenciada por la variable GFS\_FPG2 a través de una influencia estática que está activa cuando la condición GFS\_A1=1 es verdadera. Los componentes subyacentes son SRVh, Tfqq y GFsp definidos en la Tabla 2..

```
SRVh_Tfqq_GFsp:  
condition (GFS_A1=1)  
{GFS_FPG2 -S-> GFS_FQG2:  
gain in [-0,3630,-0,3411], delay=5;}
```

Siguiendo una metodología de modelado orientada a componentes, el lenguaje Ca~En permite al usuario especificar modelos genéricos (model), que pueden invocarse e instanciarse a petición. La definición de un modelo incluye un listado de *argumentos formales*, seguidamente se asigna un nombre y una lista correspondiente de *argumentos reales* a cada instanciación. Por ejemplo, un modelo genérico gen puede definirse de este modo:

```
model gen (variable X in [0., +∞], boolean parameter AA, constant G, constant R) { variable  
Y;  
i1: condition (AA) X-D1->Y: gain = G, resptime = R;  
init Y = 2; }
```

El modelo gen puede entonces invocarse mediante:

```
gg: instance gen (XX, true, 4, 2);
```

El nivel global está compuesto de restricciones numéricas funcionales asociadas con dominios de intervalos, por ejemplo restricciones derivadas de leyes físicas. En otras palabras, una restricción global es cualquier ecuación algebraica, que puede ser no-lineal, en la que se asume que cada elemento desconocido asume valores de intervalo. Ello nos permite gestionar información no precisa también en este nivel. Las restricciones globales se expresan mediante operadores aritméticos tradicionales: +, -, \*, / y \*\*. Estos operadores se interpretan en el álgebra de intervalos.

Puesto que las variables y los parámetros pueden asumir valores intervalares, es fácil adaptar la granularidad del modelo a los requisitos de los fallos. Por consiguiente, Ca~En presenta una amplia cobertura de fallos, desde aquellos que cambian radicalmente el comportamiento del sistema físico a aquellos que provocan ligeras desviaciones.

La estructura interna de Ca~En presenta dos módulos de procesamiento que corresponden a las tareas principales que deben realizarse en un diagnóstico de fallos:

- Un módulo de detección de fallos basado en un mecanismo de predicción de intervalos causales;

- Un módulo de aislamiento de fallos basado en una abstracción de los modelos en cuanto a modelos causales temporales.

El lector puede remitirse a (Travé-Massuyès y Jimenez, 2001) para obtener más detalles sobre los algoritmos.

### 3.2 El módulo de detección de fallos

En los sistemas basados en modelos, la tarea de detección de fallos puede llevarse a cabo mediante un mecanismo de predicción:

- La utilización del modelo del sistema (que puede tratarse de una simulación en los modelos dinámicos) permite obtener una predicción del comportamiento esperado del sistema,
- la decisión sobre la existencia de un fallo se basa en la comparación del comportamiento esperado y del comportamiento observado y la evaluación de las diferencias obtenidas, denominadas *residuos*.

En este apartado mostramos cómo se utiliza la representación en dos niveles del sistema físico para simular el comportamiento del sistema y obtener decisiones sólidas sobre la existencia de fallos. Se ilustra el algoritmo de bucle semi-cerrado para la detección de fallos que se utiliza en Ca~En, junto con algunos ejemplos que muestran claramente el equilibrio entre la sensibilidad y la robustez.

#### 3.2.1 El módulo de predicción de Ca~En

El algoritmo de predicción realiza una estimación de los valores de las variables endógenas a lo largo del tiempo. Puede operar en un modo de *bucle abierto*, es decir, como mera *simulación*, o en un modo de *bucle cerrado* o *predicción*, es decir, teniendo en cuenta en tiempo real los valores de las variables medidas para corregir la deriva temporal del modelo debida a la incertidumbre del mismo (sus parámetros son intervalos).

La unidad temporal del módulo de predicción es la misma que el sistema de obtención de datos. Los datos de entrada son el modelo causal, las condiciones iniciales, y la evaluación de las variables exógenas y otras variables medidas a lo largo del tiempo. La salida del modelo son las trayectorias de cada variable procesada (Travé-Massuyès and Milne, 1997).

El módulo de predicción puede utilizarse de forma autónoma o junto con el módulo de detección de fallos, en cuyo caso se utilizará en un modo de *bucle semi-cerrado* (SCL, de *Semi-Closed Loop*) tal como se explica en el apartado 3.2.2.

En Ca~En, se ejecutan dos pasos para pronosticar los valores de las variables: en el nivel de restricciones locales y en el nivel de restricciones globales.

*a) Nivel de restricciones locales: computación de los valores de las variables actualizados*

Según el teorema de superposición válido para el caso lineal, la computación del valor actualizado de una variable  $Y$  consiste en el procesamiento de la suma de las influencias desencadenadas que han actuado sobre la variable durante el último intervalo de tiempo.

Consideremos en primer lugar que  $y$  se ve afectada por sólo una variable, p.ej.  $x$ , por una influencia de un tipo determinado. Según el tipo de influencia, la tabla 4 proporciona la forma interna de la influencia discreta utilizada por Ca~En, así como su equivalente continua.

Influencia	Formalismo de representación	Función de transferencia (ecuación dif. o algebraica)	Función de transferencia discreta (forma interna de Ca~En)
Dinámica 1	$X \rightarrow D1 \rightarrow y$	$\frac{Y(s)}{X_i(s)} = \frac{Ke^{-sT_d}}{1 + \tau s}$	$y(t+1) = a_{D1} y(t) + b_{D1} x_i(t-d)$ (1)

Dinámica 2	$X \rightarrow D2 \rightarrow y$	$\frac{Y(s)}{X_i(s)} = \frac{K\omega^2}{s^2 + 2\xi\omega s + \omega^2}$	$y(k+1) = a1_{D2}y(k) + a2_{D2}y(k-1) + b1_{D2}u(k) + b2_{D2}u(k-1)$ (2)
Integral	$X \rightarrow I \rightarrow y$	$\frac{Y(s)}{X_i(s)} = \frac{K}{T_s s}$	$y(t+1) = a_I y(t) + b_I x_i(t-d)$ (3)
Estática	$X \rightarrow S \rightarrow y$	$\frac{Y(s)}{X_i(s)} = K$	$y(t+1) = K x_i(t+1-d)$ (4)
Constante	$X \rightarrow C \rightarrow y$	$Y(s) = C$	$y(t+1) = C$ (5)

**Tabla 4.** Diferentes tipos de influencias de Ca-En y sus formas internas.

Los símbolos que se utilizan en la tabla 4 tienen los siguientes significados:

- $T_s$  es el parámetro del período de muestreo;
- $K$  y  $\tau$  son las constantes de ganancia y tiempo de la función de transferencia de primer orden.  $\tau$  corresponde con bastante exactitud a  $T_r/3$ , siendo  $T_r$  el tiempo de respuesta (parámetro `resptime`);
- $\xi$  y  $\omega$  son la relación de amortiguación y la frecuencia natural de la función de transferencia de segundo orden;
- $a_{D1} = e^{-T_s/\tau} \approx e^{-3T_s/\tau}$ ,  $b_{D1} = K(1 - a_{D1})$ ;
- $a_I = 1$ ,  $b_I = KT_s$ ;
- $a1_{D2}, a2_{D2}, b1_{D2}, b2_{D2}$  son los parámetros de la función de transferencia discreta de segundo orden, cuya expresión depende del tipo de sistema (sobamortiguado o sobreamortiguado, con ceros o sin ceros,...).


Generalicemos ahora a una variable  $y$  influenciada (de forma activa) por un conjunto de variables  $X = \{x_i, i=1, \dots, n\}$ . Las influencias  $I_i, i=1, \dots, n$ , pueden ser de índoles diferentes. Definiremos  $X_D, X_I, X_S$  y  $X_C$  como los subconjuntos de variables de  $X$  que influyen sobre  $y$  mediante influencias dinámicas, integrales, estáticas y constantes, respectivamente. Las influencias dinámicas ( $I_i \in I_D$ ), las influencias integrales ( $I_i \in I_I$ ), las influencias estáticas ( $I_i \in I_S$ ) y las influencias constantes ( $I_i \in I_C$ ) deben combinarse. Cada influencia se materializa en primer lugar mediante una variable intermedia que representa a su *influencia marginal* asociada (este paso no es necesario para las influencias estáticas y constantes). Los conjuntos de variables intermedias son  $V_D$  y  $V_I$  para influencias dinámicas e integrales, respectivamente. La combinación se efectúa sumando todas las influencias marginales mediante influencias estáticas, tal como se ilustra en la Figura 2 donde las flechas dobles representan conjuntos de influencias.

$v_i \in V_D$  se actualiza según (1) o (2) en la tabla 4, según el orden de la función de transferencia.  $v_j \in V_I$  se actualiza según (3). Finalmente, en cada instante de muestreo, y viene dado por:

$$y(t) = \sum_{v_i \in V_D} v_i(t) + \sum_{v_j \in V_I} v_j(t) + \sum_{x_k \in X_S} K_k x_k(t - d_k) + \sum_{I_l \in I_C} C_l \quad (6)$$

siendo  $K_k$  las ganancias de las influencias estáticas y  $C_l$  las constantes de las influencias constantes.

Observe que las características temporales captadas por los retardos y los tiempos de respuesta, se tienen en cuenta automáticamente. El resultado es un intervalo.




**Figura 2.** Combinación de influencias en Ca~En.

*b) Nivel de restricciones globales: depuración de los valores de la variable actualizados*

Los intervalos numéricos obtenidos para los valores actualizados (Ecuación (6)) se depuran con las restricciones globales mediante un algoritmo de propagación de tolerancias (Hyvönen, 1992) en el conjunto de variables. El efecto del algoritmo de propagación de tolerancias es filtrar (reducir) los valores  $y(t)$  en búsqueda de consistencia utilizando las restricciones globales.

Las envolventes proporcionan los límites superior e inferior de los valores de la variable en cada instante muestreado. Como consecuencia del razonamiento basado en intervalos utilizado en Ca~En, los resultados son completos, pero no son correctos (Armengol *et al.*, 2000). La generación de envolventes es uno de los pasos más críticos del método de detección de fallos basado en modelos intervalares. Las envolventes deben ser lo suficientemente restrictivas para detectar fallos, pero no excesivamente sensibles para evitar generar falsas alarmas (Tornil *et al.*, 2001).

En la figura 3 se muestra una pantalla del sistema TIGER-SHEBA que ilustra un ejemplo de las envolventes generadas por Ca~En.



**Figura 3.** Visualización de envolventes generadas por Ca~En en el sistema TIGER-SHEBA.

### 3.2.2 Estrategia de detección de fallos SCL del Ca~En

El procedimiento de detección de fallos del Ca~En está basado en modelos de comportamiento normal. Se trata de modelos con parámetros inciertos que capturan la imprecisión de la modelización del sistema. Las predicciones en línea que se obtienen a partir de estos modelos constituyen la base de un procedimiento de detección de discrepancias basado en envolventes, las cuales se comportan como umbrales adaptativos que definen el rango de valores de las variables del sistema sin fallos en defuncionamiento. Para ello se comparan las envolventes obtenidas con los valores observados de las variables a lo largo del tiempo con el objetivo de detectar discrepancias estáticas y dinámicas. Ello es esencial para sistemas controlados (Quevedo *et al.*, 2000), como las turbinas, en los cuales el controlador tiende a compensar los fallos, de forma que este sólo podría ser observable, y por lo tanto detectable, durante la respuesta transitoria de la turbina. Las variables generalmente se estabilizan entonces en valores normales. Un sistema clásico de diagnóstico basado en umbrales estáticos acostumbra a no ser eficaz en este tipo de situaciones.

Puesto que el objetivo final del Ca~En es aislar los fallos, se efectúa un desacoplamiento de cada variable medida. Ello significa que los valores medidos en las variables siempre se utilizan para determinar la predicción de las variables influenciadas por estas. Por ejemplo para una influencia estática en la que  $K=[K_{min}, K_{max}]$ , tendríamos:


$$\hat{y}_{pred}(t+1) = Kx_{med}(t-d) \quad (7)$$

Los sufijos “pred” y “med” son las abreviaturas de predecida y medida, respectivamente.

En cada instante  $t$  y para cada variable medida  $y$ , Ca~En comprueba si el valor medido  $y_{med}(t)$  (un número real) pertenece o no al valor pronosticado  $\hat{y}_{pred}(t)$  (un intervalo). En caso negativo, se dice que la variable  $y$  es una variable sospechosa (*alarming*) en el tiempo  $t$ . La evaluación se realiza mediante el cálculo del residuo intervalar:

$$r_y(t) = y_{pred}(t) - y_{med}(t) \quad (8)$$

donde  $0 \notin r_y(t)$  en el caso erróneo y  $0 \in r_y(t)$  de lo contrario. Definiremos *SOSP* como el conjunto de variables sospechosas en el que  $0 \notin r_y(t)$ . Desde el punto de vista gráfico, se interpreta como que la trayectoria de la variable observada queda fuera de su envolvente en el tiempo  $t$ , tal como se muestra en la Figura 4.



**Figura 4.** La detección de fallos se basa en umbrales adaptativos.

En la práctica, debe tenerse en cuenta las influencias del ruido u otros tipos de perturbaciones. En estas situaciones, una incompatibilidad local entre el pronóstico y la observación en un instante  $t$  no significa necesariamente que el sistema presente fallos. En las aplicaciones reales, es muy importante tener un sistema de detección de fallos robusto, pues un sistema que informara incorrectamente de la presencia de fallos pronto perdería la confianza del operador y del personal de ingeniería. Por ello se utiliza un indicador más robusto que las meras variables sospechosas de fallos. Se informa de la presencia de un fallo cuando una variable ha sido una variable sospechosa durante todo un intervalo de tiempo  $T$  significativamente superior al período de muestreo (véase Figura 4). En ese caso decimos que la variable es anómala (. El valor de  $T$  puede considerarse un múltiplo del período de muestreo,  $T = \nu T_s$ , y debería ajustarse teniendo en cuenta el ruido inherente en los sensores.

Más formalmente, el conjunto *ANOM* de variables con comportamiento anómalo puede definirse de este modo:

$$y \in \mathcal{ANOM} \text{ en el momento } t \text{ si } y \in \mathcal{A} \text{ en todo } t-\nu, \text{ es decir, } \forall i = 0, \dots, \nu, 0 \notin r_y(t-i) \quad (9)$$

Dentro del marco presentado más arriba, la estrategia de detección de fallos del Ca~En es una estrategia mixta que combina una estrategia de tipo observador (modo de bucle cerrado) con una estrategia de simulación (modo de bucle abierto) para determinar los residuos y seguir evaluando el estado de cada variable. Esta estrategia se conoce como *estrategia de bucle semi-cerrado (SCL)* (Escobet *et al.*, 2001).

El control del modo (bucle abierto o bucle cerrado) depende de si el valor observado de  $y$  se encuentra dentro de su envolvente (situación normal) o fuera (situación sospechosa), tal como se ilustra más abajo para una función de transferencia de primer orden:

Si  $y \notin \mathcal{SOSP}$  - modo de bucle cerrado, en ese caso



$$y_{pred}(t+1) = a_D y_{med}(t) + b_D x_{med}(t-d) \quad (10)$$


Si  $y \in SOS\mathcal{P}$ - modo de bucle abierto, en ese caso

$$y_{pred}(t+1) = a_D y_{pred}(t) + b_D x_{med}(t-d) \quad (11)$$

siendo  $a_D \in [a_{Dmin}, a_{Dmax}]$  y  $b_D \in [b_{Dmin}, b_{Dmax}]$ .


Los dos modos mencionados corresponden a los esquemas de la Figura 5a (modo en bucle cerrado) y la Figura 5b (modo en bucle abierto). El concepto bajo esta estrategia mixta está relacionado con dos cuestiones:

- El modo de bucle cerrado funciona sólo en pronósticos de un paso adelante, obteniendo de este modo una buena precisión, que resulta de vital importancia cuando se utilizan modelos de intervalos (Armengol *et al.*, 2000).
- En cuanto la variable se convierte en sospechosa, el uso de un modo de bucle cerrado comportaría que la predicción siguiera al fallo, con lo cual el procedimiento de detección de fallos no detectaría el error.



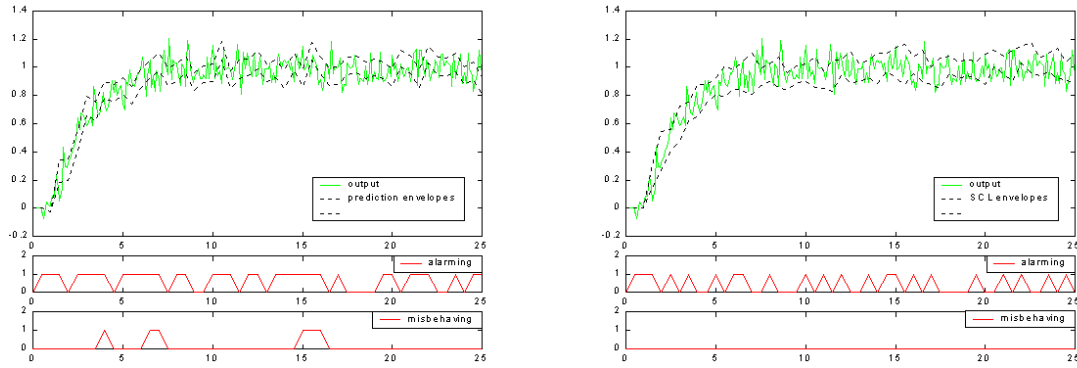
**Figura 5.** a. Detección en bucle cerrado (predicción). b. Detección en bucle abierto (simulación).

En la Figura 6 se muestra una comparación entre los modos de bucle abierto y de bucle cerrado. Las envolturas dibujadas corresponden a una influencia dinámica con los parámetros de intervalo  $K=[0.75,1.25]$  y  $\tau=[1.75,2.25]$  (el período de muestreo es 0,5). Puede observarse que el modo de bucle cerrado (línea continua) produce envoltorios menos conservadores.



**Figura 6.** Envolturas utilizando bucle cerrado (línea punteada) y envolturas en bucle abierto (línea discontinua).


En la figura 7, la estrategia SCL de  $Ca \sim En$  se compara con la estrategia de bucle cerrado en presencia de ruido. Se considera un sistema de primer orden con  $K = 1$  y  $\tau = 2$  y para la generación de envolturas se han utilizado los valores intervalares  $K = [0.75, 1.25]$  y  $\tau = [1.75, 2.25]$ .



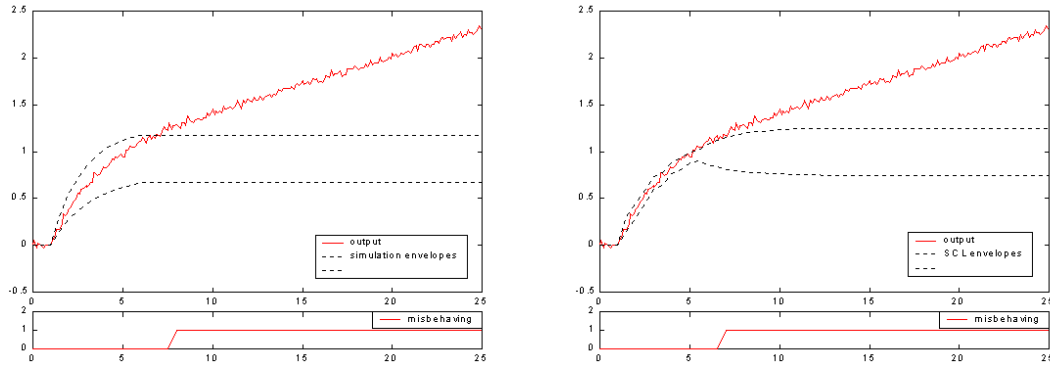
**Figura 7.** Detección en presencia de ruido **a.** detección en bucle cerrado. **b.** estrategia de detección SCL.

En figuras anteriores 7.a y 7.b, las gráficas centrales muestran la señal binaria que indica cuándo la salida del sistema sale de las envolventes (señal sospechosa); las gráficas inferiores muestran las señales anómalas obtenidas utilizando  $\nu=3$ . Puede observarse que utilizando la estrategia SCL de  $Ca \sim En$ , la salida del sistema puede situarse fuera de las envolventes hasta en un máximo de dos muestras consecutivas. Ello significa que para evitar falsas alarmas se puede utilizar un umbral temporal *sospechosa-anómala* igual a 3. También puede observarse que se necesita un umbral mucho más alto para evitar falsas alarmas cuando se utiliza la estrategia de bucle cerrado, lo cual comporta un tiempo de detección superior.

Cuando aparece un fallo, la estrategia SCL puede discriminar entre ruido y el efecto del fallo. En las Figuras 8a y 8b, se comparan los comportamientos de la estrategia SCL y la simulación cuando surge un fallo brusco (en  $t=3$  seg.). En las Figuras 9a y 9b se comparan las mismas alternativas en el caso de un fallo de tipo deriva. En ambos casos, puede observarse que SCL comporta tiempos de detección inferiores.



**Figura 8.** Detección de un fallo brusco **a.** basada en una simulación. **b.** basada en estrategia SCL.



**Figura 9.** Detección de un fallo de tipo deriva **a.** basada en simulación. **b.** basada en estrategia SCL.

### 3.3 El módulo de aislamiento de fallos

Tras detectar una o varias variables con comportamientos anómalos, el sistema busca las posibles causas que los origina y elabora un listado de diagnósticos potenciales. Un diagnóstico es un conjunto mínimo de componentes para los que la invalidación de la suposición de comportamiento normal (*SD*, *COMP*, *OBS*) es consistente desde un punto de vista lógico, siendo *SD* una descripción formal del sistema que incluye suposiciones de comportamiento normal para el conjunto *COMP* de componentes y los componentes en *COMP* son las unidades de diagnóstico elementales. En el método de diagnóstico de Ca~En, la estructura causal (incl. aspectos temporales) actúa como *SD* y las propias influencias son los elementos de *COMP*. Las influencias con fallo quedan asociadas a sus correspondientes componentes. Entre los aspectos temporales se incluyen tiempos de retardo, así como la dinámica introducida por los diferentes modos operativos capturados por las condiciones de activación de influencias y la condición de activación asociada.


Los diagnósticos se computan a partir de la recopilación de *conjuntos conflictivos*, es decir conjuntos de componentes en los que las observaciones indican que como mínimo uno de los componentes del conjunto debe tener un comportamiento anómalo, mediante un algoritmo denominado *incremental hitting set algorithm* (Levy, 1989). Se proporcionan el conjuntos de componentes posibles con fallo etiquetados mediante su correspondiente tiempo de aparición del fallo.

El proceso de diagnóstico se inicia tan pronto como se avisa de la presencia de una variable con comportamiento anómalo - Para una variable, p.ej. *X*, el procedimiento de generación de conflictos se remonta hacia atrás en el gráfico causal, siguiendo la intuición de que las influencias que pueden ser el origen del comportamiento anómalo de *X* son aquellas relacionadas con las trayectorias que llegan a dicho nodo desde los nodos correspondientes a las primeras variables medidas. Este grupo de influencias, conocido como *influencias ascendentes* de *X*, se registra como conjunto conflictivo.

**Proposición 3.1.** El grupo de *influencias ascendentes* de una variable anómalas *X* es un grupo conflictivo (o, por brevedad, simplemente conflicto).

Los conjuntos conflictivos caracterizados por la proposición 3.1 corresponden a las discrepancias originadas por las variables anómalas.

Consideremos el gráfico causal de la Figura 10, en el que se miden todas las variables excepto *U*, y las etiquetas *I*<sub>1</sub>, *I*<sub>2</sub>, *I*<sub>3</sub>, *I*<sub>4</sub>, y *I*<sub>5</sub> denotan las influencias entre variables. Asumamos que la variable *X* presenta un comportamiento anómalo y que *Y* es correcta. En ese caso, según la proposición 3.1, {*I*<sub>1</sub>, *I*<sub>2</sub>, *I*<sub>4</sub>} es un conjunto conflictivo.



**Figura 10.**  $X$  presenta un comportamiento anómalo,  $Y$  no presenta un comportamiento anómalo,  $U$  no se ha medido.

Cuando se consideran modelos de fallos genéricos, también puede obtenerse otro conjunto conflictivo si se tienen en cuenta las variables que no presentan un comportamiento anómalo. El hecho de que una variable determinada no presenta un comportamiento anómalo puede proporcionarnos información para depurar el diagnóstico si pueden realizarse algunas suposiciones específicas. Sin embargo, no todas las variables que no presentan un comportamiento anómalo resultan útiles; intuitivamente sólo deben considerarse aquellas variables que tienen como mínimo una variable causalmente sin medir de forma ascendente en común con una variable que presenta un comportamiento anómalo. Éste es el caso de  $Y$  con respecto a  $X$  en nuestro ejemplo.

En nuestro dominio, y dado el tipo de influencias consideradas, la *suposición de exoneración de fallo individual* resulta especialmente interesante. Se interpreta mediante la consideración de que siempre se manifiesta una y sólo una influencia errónea por el comportamiento de sus variables medidas de forma descendente. También se conoce como la suposición de exoneración de fallo individual basada en ARR (*Analytical Redundancy Relation*) (Cordier *et al.*, 2000).

Volviendo al ejemplo, asumamos que las influencias  $I_1$  y  $I_4$  funcionan correctamente, lo cual implica que la influencia errónea es  $I_2$ . Puesto que  $U$  no se mide, se detecta mediante el comportamiento anómalo de  $X$ . Por lo pronto,  $Y$  es correcto, lo cual no es consistente con la suposición de exoneración si se supone que las influencias  $I_3$  y  $I_5$  son correctas. Por lo tanto,  $I_3$  y  $I_5$  deben ser erróneas para compensar la propagación de la anomalía de  $I_2$ . Por consiguiente, si asumimos que  $I_1$  y  $I_4$  son correctas, no podemos asumir que también lo son  $I_3$  o  $I_5$ . Así pues,  $\{I_1, I_4, I_3, I_5\}$  es otro conjunto conflictivo. Este razonamiento puede generalizarse con la siguiente proposición:

**Proposición 3.2.** Si una variable  $Y$  que no presenta un comportamiento anómalo tiene como mínimo una variable causalmente no medida de forma ascendente en común con una variable  $X$  que presenta un comportamiento anómalo, en ese caso la diferencia simétrica<sup>1</sup> de los grupos de las influencias ascendentes de  $Y$  y de  $X$  es un conjunto conflictivo.

La determinación de todos los conjuntos conflictivos de este tipo requiere un algoritmo recursivo que considere todas las variables con comportamientos anómalos y la clase de variables correctas que tienen una influencia ascendente en común (Travé-Massuyès y Jimenez, 2001).

En resumen, se ha demostrado que pueden perfilarse dos tipos de conjuntos conflictivos cuando una variable presenta un comportamiento anómalo. Estos dos tipos de conjuntos conflictivos no están basados en el mismo concepto. El primero está basado en el hecho de que el comportamiento anómalo de una variable se explica por el hecho de que como mínimo una influencia ascendente es errónea, independientemente de cualquier suposición. El segundo tipo de conflictos se apoya en el hecho de que una influencia errónea provoca el comportamiento anómalo de las variables descendentes a menos que sea compensado mediante otra influencia errónea. Observe que podría ser que el fallo estuviera oculto debido a la falsedad de la computación de intervalos que puede generar comportamientos falsos (a pesar de que la probabilidad puede considerarse muy baja). Esto explica que los conflictos obtenidos al analizar retrospectivamente el gráfico causal a partir de las variables con comportamientos anómalos se conozcan como *conflictos primarios*, mientras que los conflictos responsables de las variables sin comportamientos anómalos se conozcan como *conflictos secundarios*.

Tal como explicaremos más tarde, esta distinción proporciona las bases para la definición de un criterio de preferencias para los diagnósticos generados.

<sup>1</sup> La diferencia simétrica de los dos grupos es su unión sin su intersección.

La generación de diagnósticos se basa en generar los conjuntos mínimos afectados de la colección de conflictos generados por un algoritmo superior. Puesto que a lo largo del tiempo pueden aparecer síntomas nuevos para un fallo determinado, es importante que el procedimiento de diagnosis sea creciente. En Ca~En, utilizamos el algoritmo de Levy (Levy, 1989) que es una versión incremental revisada del original de Reiter (Reiter, 1987). Los diagnósticos se clasifican en función de si sus elementos pertenecen meramente a conjuntos conflictivos primarios o no. Podemos definir un *elemento de conflicto secundario* como el que pertenece a un conflicto secundario y no pertenece a ningún conflicto primario. Entonces, la *clase de preferencias* de un grupo de diagnóstico se define como el número de elementos de conflictos secundarios que contiene. Cuanto más pequeña sea la clase de preferencias de un grupo de diagnóstico, mayor será la preferencia del diagnóstico en cuestión.

La Figura 11 inferior es una pantalla del sistema TIGER-SHEBA que ilustra el procedimiento de aislamiento en la turbina Frame 6 .

```
[Replay] 11:58:27 19/11/1999 CAEN: Gas fuel system problem detected

mined by
:27 19/11/1999 » GFS model isolation [ GCVm CGCV ]
units for
:27 19/11/1999 » GFS model isolation [ GCVm CGCV ]
:28 19/11/1999 » GFS model isolation [ HSS ]
:29 19/11/1999 » CAEN: Turbine problem detected
:36 19/11/1999 » GFS model isolation [ HSS ]
*message present in area gas_fuel
:27 19/11/1999 $ Gas fuel stroke high [L60FSGH] change from 0 to 1
:37 19/11/1999 $ Gas fuel speed ratio valve position rapid decrease
*message present in area caen_alarm
:29 19/11/1999 » Whole turbine model isolation [ sis ]
:37 19/11/1999 » Whole turbine model isolation [ sis ]
*message present in area caen_alarm
:27 19/11/1999 Model FPG2 Lower envelope alarming [M-FPG2LA] change from 1 to 0
:27 19/11/1999 Model FSG Lower envelope misbehaving [M-FSGLB] change from 0 to 1
:27 19/11/1999 Model FSGR Upper envelope alarming [M-FSGRUA] change from 0 to 1
:28 19/11/1999 Model FSGR Upper envelope misbehaving [M-FSGRUB] change from 0 to 1
:29 19/11/1999 Model FSG Lower envelope alarming [M-FSGLA] change from 1 to 0
:29 19/11/1999 Model FSG Lower envelope misbehaving [M-FSGLB] change from 1 to 0
:30 19/11/1999 Model FQG Lower envelope alarming [M-FQG2LA] change from 0 to 1
:31 19/11/1999 Model FQG Lower envelope alarming [M-FQG2LA] change from 1 to 0
:35 19/11/1999 Model FSG Lower envelope alarming [M-FSGLA] change from 0 to 1
:36 19/11/1999 Model FPG2 Upper envelope alarming [M-FPG2UA] change from 0 to 1
:36 19/11/1999 Model FSG Lower envelope misbehaving [M-FSGLB] change from 0 to 1
:37 19/11/1999 Model FPG2 Upper envelope alarming [M-FPG2UA] change from 1 to 0
:37 19/11/1999 Model FSG Lower envelope alarming [M-FSGLA] change from 1 to 0
:37 19/11/1999 Model FSG Lower envelope misbehaving [M-FSGLB] change from 1 to 0
```

Figura 11. Fallos mostrados por el sistema TIGER-SHEBA.

## 4 La metodología de modelado del Ca~En

La metodología de modelado del sistema Ca~En aprovecha los métodos de modelado automático. Recordemos que la extensión del método de ordenación causal (Iwasaki y Simon, 1994) en sistemas híbridos fue propuesta por (Travé-Massuyès y Pons, 1997) como un requisito para el modelado del Ca~En. Además de este método, se han incorporado otras características de modelado que se describen en este documento. Se presentan cada uno de los pasos del método de modelado: la generación automática de una estructura causal a partir de un modelo de ecuaciones orientado a los componentes y cómo obtener los parámetros de las influencias causales, y seguidamente cómo derivar automáticamente los modelos de detección operativos.

### 4.1 Generación de la estructura causal de nivel local con Causalito

Varios autores han hablado del problema de la ordenación causal, generalmente para proporcionar una explicación de porqué un dispositivo tiene un determinado comportamiento. Entre todas las estrategias existentes, nos hemos centrado en la ordenación causal de Iwasaki y Simon (1994). Estamos de acuerdo con su idea principal, que consiste en derivar la ordenación causal a partir de un análisis estructural de las ecuaciones. Nuestro software *Causalito* implementa un algoritmo de ordenación causal ampliado (Travé-Massuyès y Pons, 1997).

Los primeros requisitos para el Ca~En se derivan del hecho de que la predicción que constituye la base del mecanismo de detección de fallos se realiza a lo largo de la estructura causal. Ca~En necesita una estructura causal completa de forma que cualquier variable endógena debe ser accesible desde el grupo de variables exógenas, siendo por lo tanto necesario realizar una interpretación de los bucles.

El segundo requisito es que debemos proporcionar una ordenación causal para sistemas de modos múltiples (sistemas híbridos). Con sistemas de modos múltiples nos referimos a sistemas en los que hay algunos componentes como interruptores o válvulas presentan un comportamiento todo o nada, incorporando o replegando nuevas bifurcaciones al circuito. El modelo de ecuaciones de dichos sistemas tiene condiciones asociadas a algunas de las ecuaciones. En lugar de generar una nueva estructura causal para cada modo, Causalito lleva a cabo una generación creciente de la estructura causal. En primer lugar computa una estructura causal en un modo determinado, pasa a otro modo y computa los cambios mínimos en la estructura causal que comporta el cambio de modo. Se consideran todas las configuraciones posibles del circuito. Así pues las influencias de la estructura causal final se etiquetan con una condición de activación que refleja el estado (discreto) de los componentes de modo múltiple.

Causalito toma como información inicial la matriz de incidencia del sistema en la que el elemento  $m_{ij}$  es 1 o 0 según si la variable  $X_j$  aparece o no en la ecuación  $E_i$ . Causalito construye un gráfico bipartito  $G$  en el que cada variable  $X_j$  y ecuación  $E_i$  se representan mediante un nodo y en el que existe un linde entre  $X_j$  y  $E_i$  si  $m_{ij}$  es 1. Para encontrar la estructura causal correspondiente, primero se computa una concordancia perfecta en el gráfico  $G$ . Orientando los lindes de la concordancia perfecta desde los nodos de la ecuación a los nodos de la variable y el resto de lindes desde los nodos de la variable a los nodos de la ecuación, obtenemos una primera estructura causal en la que las ecuaciones (relaciones) aparecen de forma explícita. Esta estructura también se conoce como *Grafo de Resolución* (GR) (Cassar y Staroswiecki, 1997).

Esta estructura causal manifiesta el flujo de computaciones de variables. Está formada por niveles alternos de variables y relaciones. Para resolver una relación  $r_i$  para su variable emparejada, deben resolverse todas las variables de entrada de  $r_i$ . Todas las relaciones se etiquetan con su correspondiente componente.

La estructura de influencia causal final se obtiene agregando el nodo de la ecuación y el nodo de la variable asociado mediante ~~perfect matching~~ *(concordancia perfecta)*. Para consultar el procedimiento detallado, consulte (Travé-Massuyès y Pons, 1997).

## 4.2 Derivación de los modelos de detección operacionales

Mientras que el modelo orientado a componentes (relaciones primarias) y su estructura causal asociada, que llamaremos *estructura causal genérica*, generados tal como se ha descrito en el apartado anterior son adecuados para el aislamiento de fallos, los modelos que pueden utilizarse para la detección de fallos, es decir, los *modelos de detección funcional*, normalmente dependen de los sensores disponibles, que pueden variar de un sistema a otro en la misma clase, p.ej. turbinas de gas.

El estudio metodológico que presentamos en este apartado analiza cómo determinar, para un sistema dado, la estructura del modelo de detección funcional y los componentes que deben asociarse con cada relación operacional. Ello se realiza a partir de la estructura genérica (y única) del modelo orientado a los componentes y se ilustra seguidamente sobre el ejemplo de GFS.

### 4.2.1 Metodología utilizada para derivar los modelos operacionales

En el Ca~En, la detección de fallos descrita en el apartado 3.2.2 exige conocer los valores de los parámetros implicados en las relaciones. En la mayoría de las aplicaciones no se conocen ninguno de los parámetros implicados en las relaciones primarias de los modelos orientados a componentes. Por lo tanto, las únicas relaciones que puede utilizarse funcionalmente para la detección de fallos son aquellas cuyos parámetros pueden estimarse a partir de los datos. Ello se apoya en la condición de que las variables que aparecen en las relaciones se miden o pueden considerarse como constantes.


Los procedimientos para la estimación de parámetros se basan en que las relaciones son causales, es decir que las variables implicadas en las relaciones son variables de entrada o de salida y que las variables de salida dependen causalmente de las variables de entrada. Por consiguiente, los modelos de detección del Ca~En tienen una representación explícita de la estructura causal subyacente. Esta estructura causal puede derivarse automáticamente a partir de la estructura causal genérica mediante una operación de agregación. En algunos casos, podría ser más apropiado utilizar también la estructura causal agregada para el aislamiento de fallos. En este caso, deben recuperarse las etiquetas de componentes que deben asociarse con toda relación funcional. Estos dos pasos se detallan a continuación.

a) *Derivación de la estructura causal de los modelos de detección operacionales*

Consideremos la estructura causal genérica que se ha obtenido del modelo orientado a los componentes aplicando el procedimiento de ordenación causal de (Travé-Massuyès y Pons, 1997). La estructura causal del modelo de detección funcional se obtiene mediante un proceso de agregación. Para cada variable no medida siguen los siguientes pasos:

- 1: Eliminar los nodos de las variables no medidas.
- 2: Agregar las trayectorias.
- 3 (opcional): Etiquetar las nuevas influencias con sus componentes.

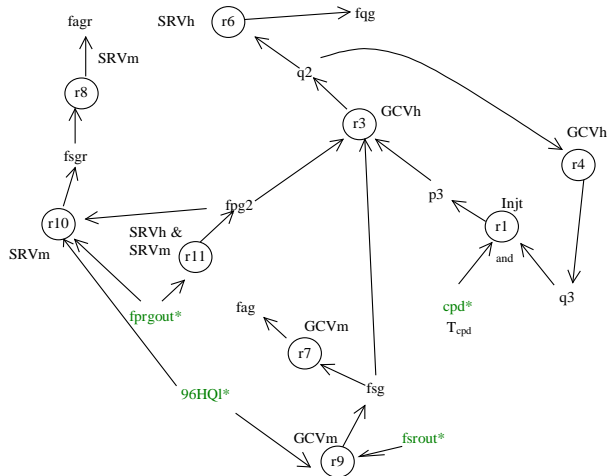
El Paso 1 consiste en eliminar, por orden, los nodos correspondientes a variables no medidas de la estructura causal genérica. Tras excluir estos nodos, las trayectorias causales en los que aparecieron estos nodos deben restaurarse en el Paso 2. Es decir, para cada variable excluida  $Y$ , debemos restaurar toda la trayectoria causal  $X \rightarrow Y \rightarrow Z$  mediante la influencia causal  $X \rightarrow Z$ . En el Paso 3, deben determinarse las etiquetas de componentes asociados con las influencias "nuevas" a partir de las antiguas. Las influencias antiguas comunes para varias trayectorias distribuyen su etiqueta de componentes asociada a todas las influencias nuevas, tal como se muestra en la figura 11.




**Figure 11.** Operaciones de agregación de la estructura causal.

**b) Aplicación al GFS de la turbina Frame 6**

En el GFS, hay 5 variables exógenas {CPD, FSROUT, FPRGOUT, P1, 96HQ1} y 4 variables endógenas medidas {FSG, FPG2, FQG, FSGR}. La estructura causal genérica del GFS se muestra en la figura 12 (Travé-Massuyès *et al.*, 2001).



**Figura 12.** Estructura causal del GFS.



**Figure 13.** Modelo funcional del GFS.

Las variables exógenas 96HQ1 y P1 se miden o no, según son variables medidas o no dependiendo de la turbina. La estructura causal funcional de aislamiento y detección de la figura 13 muestra cuatro relaciones operacionales:

- (GFS\_op1) FSG=f(FSROUT, 96HQ1)
- (GFS\_op2) FPG2=f(FPRGOUT)
- (GFS\_op3) FSGR= f(FPG2, FPRGOUT, 96HQ1)
- (GFS\_op4) FQG1= f(CPD, FSG, FPG2)

(GFS\_op1), (GFS\_op2) y (GFS\_op3) son relaciones primarias, mientras que (GFS\_op4) es una relación combinada que se obtiene combinando relaciones primarias. Ello es válido si se asume que todas las relaciones primarias pueden invertirse o pueden linearizarse alrededor de algún punto de operación. En este último caso, el dominio de validez del modelo operacional de detección se limita al entorno próximo al punto de operación.

Para determinar la etiqueta de componentes para GFS\_op4, se aplican las operaciones de agregación sobre el gráfico AND-OR de la variable FQG con las variables CPD, FSG y. El mismo procedimiento aplicado sobre (GFS\_op1), (GFS\_op2), y (GFS\_op3) nos permite concluir las asociaciones de la tabla 5.

Relaciones operacionales	Influencias operacionales asociadas	Componentes asociados
GFS_op1	Influye en FSG	GCVm   T <sub>FSG</sub>
GFS_op2	Influye en FPG2	SRVh   SRVm
GFS_op3	Influye en FSGR	SRVm   T <sub>FSGR</sub>
GFS_op4	Influye en FGR	SRVh   GCVh   Injt   T <sub>CPD</sub>   T <sub>FSG</sub>   T <sub>FOG</sub>

**Tabla 5.** Las relaciones operacionales, influencias y componentes asociados.

Una vez determinados los modelos operacionales de la aplicación deberá procederse a la estimación de los parámetros de dichos modelos, la metodología propuesta se describe en (Escobet *et al.*, 2001).

## 5 Resultados de la aplicación

La metodología presentada se ha aplicado en el dominio de aplicación de las turbinas de gas dentro del marco de los proyectos europeos TIGER y TIGER-SHEBA (Travé-Massuyès y Milne, 1997) (Milne *et al.*, 2001). Intelligent Applications Ltd (Scotland) ha comercializado el sistema de monitorización de turbinas de gas TIGER en todo el mundo. En el marco del proyecto TIGER (1992-1996), se probó el Ca~En satisfactoriamente en varios sistemas subordinados de una turbina de gas Frame 5 de General Electric, operativa en el Exxon Chemical Fife Ethylene Plant (UK), y de un grupo motor auxiliar de la empresa de aviación Dassault (F) fabricado por MicroTurbo. Más tarde Ca~En se integró completamente en TIGER dentro del proyecto TIGRE-SHEBA (1998-2000) para una turbina de gas Frame 6 de la planta de cogeneración de National Power en Aylesford (UK).

Las siguientes figuras 14 y 15 ilustran resultados de detección y aislamiento de fallos proporcionados por el Ca~En y mostrados por el sistema TIGER-SHEBA (corresponden a un modelo global de la turbina, no únicamente al GFS).



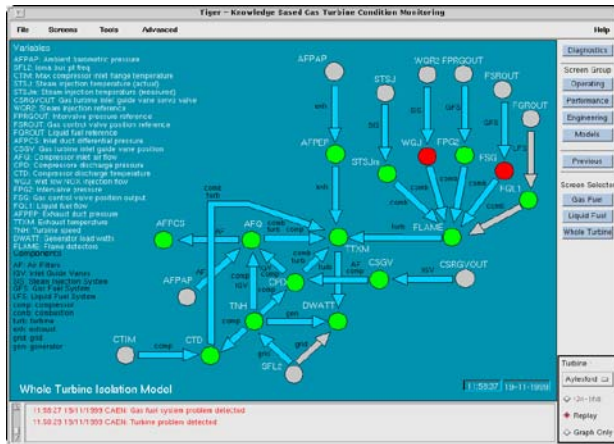


Figura 14. Incidentes de la turbina en TIGER-SHEBA




Figura 15. Envolturas mostradas en TIGER-SHEBA

## 6 Conclusión

La mayoría de tecnologías basadas en modelos se basan por completo en la bondad de los modelos y, por consiguiente, requieren métodos de modelado automatizados. Estos métodos deberían permitir a los usuarios:

- componer el modelo de un sistema complejo a partir de fragmentos de modelos
- volver a utilizar y transformar automáticamente modelos existentes;
- derivar las características del modelo a partir de los datos existentes.

Este documento presenta el sistema de diagnóstico Ca-En y su método de modelado automático. Tras la presentación de los principales principios teóricos implicados en el Ca-En, mostramos cómo puede generarse automáticamente una estructura genérica causal a partir de un modelo de ecuaciones orientado a componentes y cómo podemos derivar el modelo causal operacional utilizado por el Ca-En. Este enfoque ha sido aplicado a diversos sistemas y a modo de ejemplo mostramos el sistema de inyección de combustible de una turbina de gas Frame 6.

En relación con este trabajo, también se ha estudiado el importante tema de posibilidad de diagnosis y ubicación de los sensores. El método propuesto en (Travé-Massuyès *et al.*, 2001) está basado en un modelo causal similar al utilizado por el Ca-En.

## Agradecimientos

Damos las gracias a todos los participantes en el reciente proyecto europeo TIGER SHEBA, National Power Cogeneration y Kaverner Energy Ltd., en especial a R. Milne y C. Nicol de Intelligent Applications Ltd por su ayuda y comentarios referentes al trabajo de aplicación.

## Referencias

Armengol J., L. Travé-Massuyès, J. Vehí, and J. Lluís de la Rosa, A survey on interval model simulators and their properties related to fault detection. *Annual Reviews in Control* 24, pp. 31-39, 2000.

Bibas S., Cordier M-O., Dague P., Dousson C., Lévy F., and Rozé L.. Alarm Driven Supervision For Telecommunication Networks: I- Off-Line Scenario Generation, *Annales des Télécommunications*, vol. 9/10, pp. pp.493-500, Oct. 1996.

Cassar J.P. and Staroswiecki M. A structural approach for the design of failure detection and identification systems. In *Proc. IFAC, IFIP, IMACS Conference on 'Control of Industrial Systems'*, Belfort, France, pp. 329-334, 1997.

Cauvin S., M-O. Cordier, C. Dousson, P. Laborie, F. Levy, J. Montmain, M. Porcheron, I. Servet , and L. Travé-Massuyès, Monitoring and alarm interpretation in industrial environments, *AI Communications* 11(3, 4), 1998.

**Cordier M.-O., Dague P., Dumas M., Levy F., Montmain J., Staroswiecki M., and Travé-Massuyès L.**, A comparative analysis of AI and control theory approaches to model-based diagnosis, *ECAI '00*, Berlin, Germany, August pp.20-25, 2000.

**Dousson. C., P. Gaborit, and M. Ghallab**, Situation recognition: representation and algorithms, *Proc. 13th IJCAI Conference*, 166-172, Chambéry, France, 1993.

**Escobet T., L. Travé-Massuyès, S. Tornil, and J. Quevedo**, Fault detection of a gas turbine fuel actuator based on qualitative causal models, *European Control Conference (ECC'01)*, Porto (Portugal), 4-7 Septembre 2001, pp.2741-2746.

**Hyvönen E.**, Constraint reasoning based on interval arithmetic: the tolerance propagation approach, *Artificial Intelligence* 58, pp 71-112, 1992.

**Iwasaki Y., and H. A. Simon**. Causality and model abstraction, *Artificial Intelligence* 67, pp. 143-194, 1994.

**Lévy F.**, *Contribution à la réalisation d'un raisonneur à profondeur variable*, Université Paris Nord PhD dissertation thesis, 1989.

**Milne R., C. Nilcol, and L. Travé-Massuyès**, TIGER with model based diagnosis: initial deployment, *Knowledge-Based Systems* 14(2001), pp. 213-222.

**MONET-ILC98**, *Compendium of Industrial Applications of Model Based Systems and Qualitative Reasoning*, prepared by the MONET Industrial Liaison Committee, 1998.

**Pons R. and L. Travé-Massuyès**, Causal Ordering for Multiple Mode Systems. *11th International Workshop on Qualitative Reasoning (QR'97)*, Cortona, Italy, 1997.

**Quevedo J., V. Puig, and T. Escobet**, Model Fault detection of feedback systems: how and why to use the output of the PID controller?, *In IFAC Workshop on Digital Control. Past, present and future of PID Control (PID'00)*, Terrassa, Spain, 2000.

**Struss P., M. Sachenbacher, and C. Carlen**, Insights from building a prototype for model-based on-board diagnosis of automotive systems, *In Working Papers of the 11th International Workshop on Qualitative Reasoning (DX'00)*, Morelia, Mexico, 2000.

**Tornil S., T. Escobet, L. Travé-Massuyès, and E. Benazera**, Robust Interval Model Based Fault Detection – Satellite Attitude and Orbit Control System Case Study, *15<sup>th</sup> IFAC World Congress on Automatic Control*, Barcelona, Spain, 21-26 July 2002 (submitted).

**Travé-Massuyès L., T. Escobet, and R. Milne**. Model-based diagnosability and sensor placement. Application to a frame 6 Gas turbine sub-system, *7th International Joint Conference on Artificial Intelligence (IJCAI'01)*, Seattle (USA), 4-10 August 2001, 551-556.

**Travé-Massuyès L. and T. Escobet**, *Tiger Deliverable D523.36, APU Fuel System Model*, Esprit Project 6862: Tiger, Intelligent Applications Ltd., 1995.

**Travé-Massuyès L. and Jimenez J.A.** Fault detection and isolation in the Ca~En system. *LAAS-CNRS technical report*, Toulouse, 2001.

**Travé-Massuyès L. and R. Milne**. Gas Turbine Condition Monitoring Using Qualitative Model Based Diagnosis, *IEEE Expert Intelligent Systems & Applications*, pp. 22-31, May-June 1997.

**Travé-Massuyès L. and R. Milne**. Gaps between research and industry related to model based and qualitative reasoning, *In the proceedings of the ECAI'98 workshop on Model Based Systems and Qualitative Reasoning (QR'98)*, Brighton (UK), August 1998.