

Razonamiento temporal en tareas de diagnóstico abductivo basado en modelos^{*}

M. Campos, J. Palma y R. Marín

Artificial Intelligence and Knowledge Engineering Group
Universidad de Murcia. Campus de Espinardo. Murcia 30071. España
e-mail: mcampos@dif.um.es

Resumen Las técnicas de diagnóstico basado en modelos se han mostrado una de las más atractivas para abordar el diseño de sistemas de diagnóstico inteligente. La descripción de modelos de sistemas dinámicos hace que la inclusión de la componente temporal en las técnicas DBM sea uno de los aspectos que más atención han recibido en los últimos años, dando lugar a una serie de técnicas que se engloban dentro del área de Diagnóstico Temporal Basado en Modelos. En este trabajo presentamos un modelo sobre el que diseñar este tipo de sistemas, haciendo hincapié en la representación y gestión del tiempo mediante Redes de restricciones temporales difusas.

1. Introducción

Las técnicas de Diagnóstico Basados en Modelos (DBM) [10] se consideran como una de las técnicas más relevantes a la hora de diseñar sistemas de ayuda al diagnóstico. En este tipo de técnicas se parte de una descripción del sistema objeto de diagnóstico (de su estructura y funcionalidad o comportamiento), para determinar las causas de su mal funcionamiento. Desde el comienzo, las técnicas DBM pusieron de manifiesto la importancia de la componente temporal a la hora de describir la dinámica de sistemas [11], aumentando de esta manera la complejidad del proceso de diagnóstico.

En este contexto, hemos diseñado ACUDES [14], una arquitectura genérica para sistemas de ayuda a la decisión apoyada en un agente de diagnóstico que utiliza técnicas de diagnóstico temporal basado en modelos [15,13]. ACUDES ha sido diseñado para tratar con información de distinta naturaleza y en dominios donde la componente temporal juega un papel muy determinante. El primer dominio en el que hemos materializado ACUDES es el de las Unidades de Cuidados Intensivos (UCI), concretamente en el subdominio de las enfermedades coronarias.

Para proporcionar explicaciones útiles sobre la evolución del paciente en el contexto de los sistemas de ayuda a la decisión, se requiere un modelo que nos

^{*} Este trabajo ha sido subvencionado por los proyectos TIC2000-0873-C02-02, TIC2001-4936-E, FEDER2003-UNMU-E006 del MCyT español, así como por la ayuda PB/46/FS/02 de la Fundación Séneca de la Región de Murcia

permita capturar todos los elementos que permitan describir las complicaciones que puede sufrir un paciente durante su estancia en la UCI. Este modelo, llamado Modelo de Comportamiento Temporal (MCT) debe capturar, no solo las relaciones causales implicadas en la descripción de las enfermedades sino las relaciones temporales relativas a la evolución de las enfermedades. Esta evolución temporal puede especificarse como un conjunto de restricciones temporales entre los elementos que describen una complicación. En concreto, la componente temporal de la base de conocimiento se representa mediante Redes de restricciones temporales difusas (*Fuzzy Temporal Constraint Network*, FTCN en adelante) [1]. Por otra parte, el desarrollo de un sistema de diagnóstico debe tener en cuenta la evaluación de la credibilidad de las hipótesis generadas, y la integración en el proceso de diagnóstico de la información de contexto que afecta al modelo del sistema [13].

Hoy en día disponemos de marcos precisos para modelar, desarrollar e implementar sistemas basados en conocimiento (SBC) capaces de proporcionar consejo en la toma de decisiones clínicas. Como marco metodológico hemos empleado CommonKADS [18], que dispone de unas plantillas para tareas soportadas en el dominio médico como monitorización, diagnóstico y tratamiento, que pueden ser extendidas o combinadas para adaptarlas al problema en concreto.

En CommonKADS, toda tarea se define especificando el objetivo a alcanzar y los roles dinámicos y estáticos que intervienen en el problema [3]. El diagnóstico es una tarea analítica (a diferencia del tratamiento) cuyo objetivo es encontrar un factor causal que explique un comportamiento observado discrepante respecto a la norma o a las expectativas [2]. Nos referiremos a ella como la tarea diagnosticar.

2. Modelo de Comportamiento Temporal

Se ha abordado el proceso de diseño del MCT desde un punto de vista independiente del dominio para así proporcionar componentes de conocimiento útiles susceptibles de reutilización en otros dominios.

La Figura 1 describe un esquema de la ontología que define la estructura subyacente de la base de conocimiento. Como puede deducirse, el elemento clave del MCT es el Patrón de Diagnóstico Temporal Difuso (DFTP en adelante). Un DFTP captura las relaciones causales y temporales entre la hipótesis y sus efectos (parte derecha de la Figura 1).

Un DFTP está asociado a una HIPÓTESIS RAÍZ, definida mediante un nombre y una variable temporal (por ejemplo, (Insuficiencia Cardíaca Retrógrada,t1)), y que se usará en la especificación temporal del DFTP. La hipótesis raíz representa un posible diagnóstico y la variable temporal representa el instante de aparición. Una hipótesis raíz está a su vez asociada al menos a una MANIFESTACIÓN IMPLICADA y a cero o más HIPÓTESIS IMPLICADAS, que permiten modelar el hecho de que existen enfermedades que pueden implicar otras enfermedades. Las hipótesis implicadas se especifican de la misma forma que la hipótesis raíz, mientras que las manifestaciones implicadas se describen

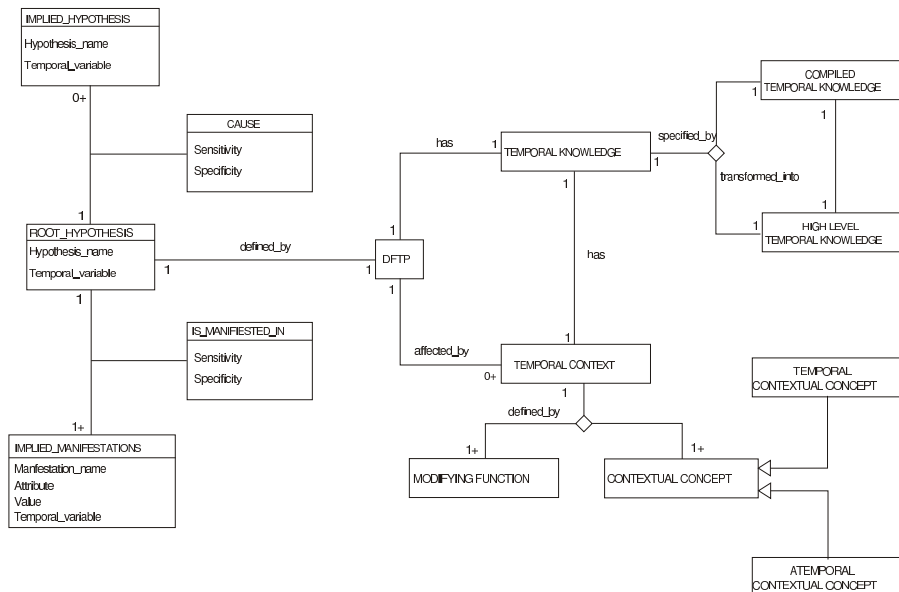


Figura 1. Ontología del Modelo de Comportamiento Temporal.

mediante un nombre, un atributo, unos valores permitidos y una variable temporal (por ejemplo (dolor, localización, {precordial}, t2)). Tanto la relación causal SE MANIFIESTA EN como CAUSA cuentan con dos atributos que definen las medidas de especificidad y sensibilidad utilizadas en Medicina basada en la Evidencia [16]. En concreto, la especificidad es una medida de la proporción de pacientes que no presentando la enfermedad, no presentan la manifestación; la sensibilidad, sin embargo, indica qué proporción de pacientes con la enfermedad presentan la manifestación.

Además del conocimiento causal, un DFTP requiere conocimiento temporal y contextual. El Conocimiento Temporal tanto en la definición del DFTP como en la especificación del contexto debe describirse en dos niveles de detalle diferentes.

- CONOCIMIENTO TEMPORAL DE ALTO NIVEL. Primero, es necesario mantener las especificaciones de las restricciones temporales proporcionadas por el experto en un lenguaje de alto nivel diseñado para este propósito ((dolor, localización, precordial, t1) APROX 5 MIN AFTER (Insuficiencia Cardíaca Retrograda,t2)).
- CONOCIMIENTO TEMPORAL COMPILADO. Segundo, esta representación de alto nivel debe traducirse al formalismo FTCN [1]. Este formalismo nos permite aplicar tareas de razonamiento temporal para:
 - inferir el conjunto completo de restricciones temporales entre elementos del patrón sin necesidad de forzar al experto a definir todas las restricciones.

- detectar las inconsistencias temporales y propagar las restricciones en la información introducida por el experto, garantizando la coherencia temporal de la base de conocimiento

Estos dos niveles de información temporal se manejan a través de FuzzyTIME [5], un Sistema de Gestión de Información Temporal que proporciona un lenguaje de alto nivel para especificación y consulta de información temporal así como un proceso de traducción para transformar las sentencias en lenguaje de alto nivel al formalismo FCTN.

Por último, un DFTP puede estar afectado por cero o más CONTEXTOS TEMPORALES que permiten modelar el hecho de que los efectos de una complicación médica pueden ser diferentes si por ejemplo se han prescrito ciertos medicamentos al paciente o existe algún factor de riesgo, como el tabaquismo. Los contextos temporales se especifican por al menos un concepto contextual, y pueden a su vez tener asociado conocimiento temporal (por ejemplo relativo a los conceptos contextuales que describen administración de medicamentos), definiendo a su vez sus propias redes de restricciones temporales. Puede encontrarse una especificación más detallada del MCT en [13,15].

3. Tarea diagnosticar

La tarea diagnosticar parte de

- un rol estático de entrada: un conjunto de eventos normales, anormales y de contexto que presenta un paciente determinado, y
- un rol estático de salida: una serie de patrones diagnósticos que se encuentran en la base de conocimiento y que pueden explicar los eventos que se producen.

En el análisis conceptual del problema propuesto, dentro del marco del Modelado de Conocimiento, es evidente que nos encontramos frente a la Tarea Analítica de Diagnóstico. Sin embargo, el diagnóstico que nos propone la librería de tareas de CK no refleja con fidelidad el proceso diagnóstico que queremos llevar a cabo. Así haremos una descripción según los distintos criterios de clasificación de un diagnóstico para describir qué tiene de particular el diagnóstico propuesto. Usamos un modelo de comportamiento anormal, ya que:

- describe fallos del sistema (hallazgos o síntomas)
- tiene conocimiento de tipo heurístico (adquisición de conocimiento a través de la herramienta CATEKAT diseñada a tal efecto dentro de la arquitectura ACUDES [14])
- sólo diagnostica los fallos descritos

Otra de las características diferenciadoras del modelo es su estructura causal-temporal-difusa basada en patrones de diagnóstico temporal difuso (DFTP). El resto de características de la tarea son:

- Cardinalidad de la explicación por fallo múltiple (múltiples fallos) y cardinalidad múltiple de cada diagnóstico(múltiples soluciones).
- Diagnóstico basado en el modelo inferencial abductivo de Flach.
- Diagnóstico basado en cobertura.

Esto nos lleva a realizar un algoritmo de diagnóstico basado en la plantilla cubrir-diferenciar, ya que la definición de la tarea Diagnosticar que ofrece Common-KADS [18] no se adapta a nuestros objetivos; así el algoritmo de diagnóstico desarrollado se basa en la plantilla cubrir-diferenciar. En la Figura 2 vemos el diagrama de inferencias correspondiente a esta plantilla [15].

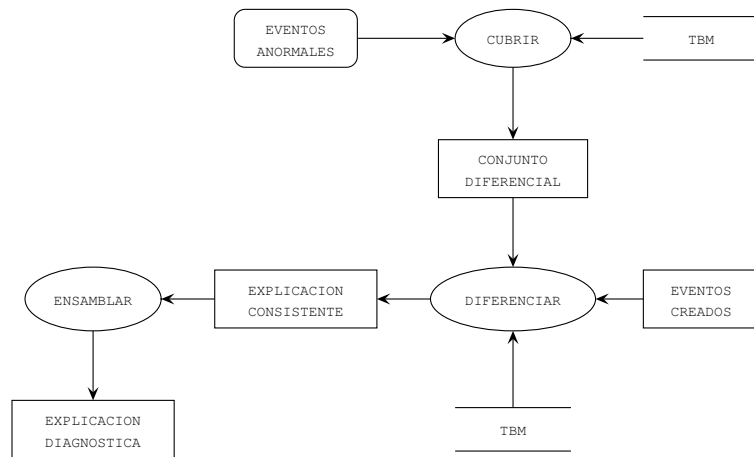


Figura 2. Diagrama de inferencias de la tarea cubrir-diferenciar.

3.1. Entradas del proceso de diagnóstico

El modelo de diagnóstico temporal teórico, descrito para este trabajo, requiere como entrada el siguiente conjunto: los observables que tienen que ser explicados, información contextual e información temporal.

El conjunto de observaciones a explicar, $EVT = \{evt_i | i = 1 \dots n_{obs}\}$ (n_{obs} es el número de eventos) dado como un conjunto de eventos $EVT = EVT+ \cup EVT-$, donde $EVT+$ representa el conjunto de eventos normales y $EVT-$ representa el conjunto de eventos anormales. Cada evento queda representado por la tupla $evt_i = (m, s, v, t)$, donde m representa la manifestación sobre la que está definida el evento, s un atributo de dicha manifestación, v representa el valor asociado a la manifestación y el atributo, t representa la variable temporal asociada a dicho evento.

- $P_{evt} : EVT \rightarrow [0, 1]$ es una función que nos indica en qué medida es posible que la observación en cuestión sea cierta.

- $N_{evt} : EVT \rightarrow [0, 1]$ es una función que nos indica el grado de necesidad asociado a la presencia del evento.
- El conjunto de observaciones de contexto $CTX_{evt} = \{ctx_i | i = 1, \dots, n_{ctx}\}$ (n_{ctx} es el número de eventos sobre el contexto) dado como un conjunto de eventos de contexto. Cada evento del contexto se representa mediante la tupla $ctx_i = (c, s, v, t)$, donde c representa un concepto del contexto sobre el que se define el evento (puede ser un concepto perteneciente a la historia del paciente o a un tratamiento al que está sujeto el paciente), s un atributo de c , v , un valor de dicho atributo y t representa la variable temporal asociada al evento de contexto.
- $R_{input} = \langle X_{input}, L_{input} \rangle$ es una FTCN consistente donde X_{input} es el conjunto de variables temporales asociadas a los eventos en EVT y los eventos del contexto, y L_{input} es el conjunto de restricciones temporales entre las variables temporales de X_{input} .

3.2. Salidas del proceso de diagnóstico

En el modelo planteado, estamos interesado tanto en obtener el conjunto de abducibles (diagnósticos etiológicos en dominios médicos) que proporcionen una explicación razonable, como también en la obtención de la red causal entre los abducibles y el resto de elementos (manifestaciones y diagnósticos fisiopatológicos en dominios médicos), así como las relaciones temporales entre estos elementos. Por lo tanto, la salida de la tarea de diagnóstico estará formada por la tupla $EXT = \langle CN_{exp}, DFTP_{exp}, BL_{exp}, AB_{exp} \rangle$, donde:

- $CN_{exp} = \langle N, A, P_{cn}, N_1, N_2 \rangle$ es el grafo que representa la red causal donde:
 - N representa el conjunto de nodos en la que cada nodo está formado por la tupla $\langle n, t \rangle$ donde n representa un concepto de tipo manifestación o hipótesis y t representa una variable temporal asociada al nodo.
 - A representa el conjunto de arcos, quedando cada arco completamente definido mediante la tupla $\langle n_i, n_k \rangle$ donde n_i y n_k son los nodos origen y destino respectivamente.
 - $P_{cn} : N \rightarrow [0, 1]$, es una función que nos indica el grado de posibilidad asociado al nodo. Si un nodo $n \in N$ está asociado a un evento $evt \in OBS$, entonces $N_{cn}(n) = N_{evt}(evt)$.
 - $N_1, N_2 : A \rightarrow [0, 1]$, son los grados de necesidad asociados a las relaciones causales entre los nodos de CN . Estas funciones son las mismas que están definidas en los patrones temporales asociados a los nodos hipótesis de la red causal.
- $R_{exp} = \langle X_{exp}, L_{exp} \rangle$ es una FCTN entre los distintos nodos de la red causal, donde X_{exp} es el conjunto de variables temporales asociadas a los nodos de CN , y L_{exp} es el conjunto de restricciones binarias que representan las duraciones entre las variables temporales.
- $DFTP_{exp}$ es el conjunto de patrones diagnósticos temporales borrosos contextualizados que han sido incluidos en la explicación.

- BL es la lista de enlaces entre las hipótesis de la red causal y los patrones temporales de diagnósticos que explican las observaciones, es $BL = \{ \langle n_i, DFTP_i \rangle \mid n_i \in N \wedge DFTP_i \in DFTP_{exp} \}$.
- AB es el conjunto de abducibles obtenidos durante el proceso de construcción de la explicación diagnóstica. Evidentemente se tiene que cumplir que $AB \subset DFTP_{ext}$.

3.3. Algoritmo de diagnóstico

En el apartado anterior se han descrito formalmente las entradas y las salidas del proceso de diagnóstico. A continuación vamos a describir el bloque básico que realiza el diagnóstico.

Concretamente, en esta sección vamos a analizar el proceso mediante el que se van añadiendo las hipótesis, representadas por sus respectivos DFTP (patrón diagnóstico), a una explicación diagnóstica. Nos centraremos en la extensión abductiva de la explicación, mediante la incorporación de DFTP ya contextualizados manteniendo la consistencia con la información temporal observada. En otras palabras, analizaremos el proceso de construcción de una explicación diagnóstica. El objetivo de la tarea cubrir es la de construir una explicación que cubra el máximo número de eventos del conjunto de eventos anormales ($EVT-$). Básicamente, el proceso consiste en ir recorriendo la lista de eventos anormales e incorporándolos a la explicación, incorporación que se puede realizar mediante uno de estos tres procedimientos[15]:

- **Subsunción.** Para evitar una proliferación excesiva de hipótesis temporalmente próximas, la tarea cubrir trata en primer lugar de incluir el evento anormal que tiene que explicar en alguna de las hipótesis ya instanciadas (hipótesis incluidas en la explicación).
- **Desplazamiento temporal.** Este proceso tiene lugar cuando al intentar realizar la subsunción esta no es posible (más adelante entraremos en los detalles del proceso de subsunción). En esta situación el evento anormal es incluido en la explicación y asociado a una nueva instancia, en diferente instante de tiempo, de una hipótesis ya instanciada en la explicación. El siguiente paso consisten en intentar subsumir en esta nueva instancia, los eventos asociados a la instancia antigua. Este proceso implica que existe una hipótesis que puede explicar un subconjunto de los eventos, en dos instantes distinto de tiempo. Esta instanciación provoca la generación de un nuevo evento anormal asociado a la nueva instancia que tiene que ser explicado, permitiendo la construcción ascendente de la red causal.
- **Generación de una nueva hipótesis.** Cuando la hipótesis que explica el evento todavía no ha sido instanciada en la explicación, no queda más remedio que instanciar dicha hipótesis en la explicación y asociarle el evento. Al igual que en el caso anterior, se debe generar un evento asociado a dicha hipótesis.

Obviamente, el proceso anterior pasa por una contextualización previa de los patrones temporales [referencia al artículo en inglés de los contextos], que consiste

Algorithm 1 Función de cobertura.

- $EVT_{new} = EVT_{anormales}(eventos\ por\ explicar)$
 - mientras $EVT_{new} \neq \phi$ hacer
 - $D =$ conjunto de de patrones (evt_i)
 - para cada $DFTP_i \in D$ hacer
 - // buscar un patrón contextualizado
 - si $DFTP_i \in DFTP_{exp}$ entonces
 - ◊ // existe una instancia de dicho patrón en la explicación
 - ◊ si ($not\ subsume(evt_i, DFTP_i, EXP)$) y $last(D) = DFTP_i$ entonces
 1. $ODFTP_{new} = desplazamientoTemporal(evt_i, DFTP_i, EXP)$
 2. $EVT_{new} = EVT_{new} \cup \{evt_h\}$
 - en otro caso
 1. $DFTP_{new} = generarNuevo(evt_i, DFTP_i, EXP)$
 2. $evt_h = asociarEvento(DFTP_{new})$
 3. $EVT_{new} = EVT_{new} \cup \{evt_h\}$
 - $EVT_{new} = EVT_{new} \setminus \{evt_h\}$
-

en comprobar si los elementos que definen cada contexto temporal junto con sus relaciones temporales están presentes, y en caso afirmativo aplicar las funciones de modificación sobre la definición del patrón.

En el Algoritmo 1 se puede apreciar en detalle como es el proceso de construcción de la explicación. Por simplicidad, omitimos los pasos de contextualización de patrones,. Se comienza buscando un patrón contextualizado perteneciente a la explicación, $DFTP_i \in DFTP_{exp}$, capaz de explicar causalmente el nuevo elemento. En caso afirmativo se intentara subsumir el evento evt_i en dicha instancia. Si la subsunción no es posible (debido a que el evento no es compatible temporalmente con la instancia de patrón) entonces se procede con el proceso de desplazamiento temporal, que al generar una nueva instancia del patrón genera un nodo evento asociado a la hipótesis principal del patrón en la red causal. En el caso de que no existiera una instancia del patrón en la explicación, obligatoriamente tenemos que crear una nueva instancia de dicho patrón y asociar el evento evt_i a dicha instancia. Este proceso se realiza mediante la función *generarNuevo* que devuelve como resultado el evento asociado a la hipótesis principal del patrón instanciado. Finalmente, el evento es eliminado de la lista de eventos a explicar. Obsérvese, que siempre que se genera una nueva hipótesis, es decir, cuando no es posible la subsunción, se genera un evento asociado a dicha hipótesis; este evento también es considerado como un evento anormal, y por tanto es necesario explicarlo.

4. Conclusiones y vías futuras

En este documento, hemos descrito un modelo de diagnóstico basado en modelos, en el que los patrones temporales son un elemento clave. Estos elementos

permiten definir un modelo de comportamiento anormal del sistema diagnosticado (el paciente en este caso) que captura todos los tipos de conocimiento casual (como se define en [7]): conocimiento fisiopatológico (relaciones causales entre estados patofisiológicos), conocimiento causal evidencial (relaciones causales entre manifestaciones externas y estados patofisiológicos o etiológicos) y conocimiento diagnóstico (relaciones entre estados patofisiológicos y etiológicos). El método de diagnóstico propuesto (sin tener en cuenta la componente temporal) es similar a las aproximaciones clásicas de diagnóstico basado en modelos (que pueden ser analizados más en profundidad en [2,10]) y es especialmente similar al llamado cubrir y diferenciar [17,9].

Nuestro modelo se basa en una FTCN, Red de restricciones temporales difusas [1,12,4], que permite representar la vaguedad asociada con las restricciones definidas entre los puntos temporales. En nuestra aproximación, cada restricción se define como una distribución de posibilidad que define el tiempo transcurrido entre dos puntos. Una de las características más importantes del formalismo es que la vaguedad inherente a la localización temporal de los síntomas, conforme son adquiridos del personal de la UCI, puede ser modelada de una forma natural [6,19,20]. Otra característica es que la red FTCN asociada con un patrón temporal especifica un orden parcial de los eventos. Este orden parcial define diferentes órdenes parciales posibles. En este sentido, cabe destacar que esta representación es más flexible que una representación basada en secuencias totalmente ordenadas y es más adecuada para el dominio médico porque no todos los pacientes presentan las manifestaciones en la misma secuencia. Por tanto, un patrón temporal no representa la secuencia típica de manifestaciones, sino que lo representado son las restricciones temporales entre estas manifestaciones, que están impuestas por relaciones causa efecto. Esta es la aportación más importante de nuestra aproximación, en contraste con otros modelos que no se basan en restricciones temporales como [8,7].

Otra de las características más destacables del modelo de diagnóstico abductivo temporal propuesto es que permite generar múltiples instancias de una misma hipótesis desplazada a lo largo del tiempo, representando la ocurrencia repetitiva de fallos.

Como utilidades relacionadas dentro de la arquitectura en la que se ha desarrollado este trabajo, además de implementar el algoritmo de diagnóstico y hacer un navegador diagnóstico, se ha construido una herramienta gráfica para que la inserción de los eventos normales, anormales y de contexto sea rápida e intuitiva. El navegador diagnóstico es una herramienta que nos permite desplazarnos a lo largo del proceso de diagnóstico (hacia delante y hacia atrás) para ver como se ha llegado al diagnóstico final, mostrando gráficamente cada uno de los pasos intermedios de los que consta el proceso diagnóstico (redes causales intermedias de la explicación diagnóstica).

Referencias

1. S. Barro, R. Marín, R. Mira, and J. Patón. A model and a language for the fuzzy representation and handling of time. *Fuzzy Sets and Systems*, 61:153–175, 1994.

2. V. Richard Benjamins. Problem solving methods for diagnosis, 1993. PhD Thesis.
3. Joost Breuker and Walter Van de Velde. *CommonKADS Library for Expertise Modelling*. IOS Press, 1994.
4. V. Brusoni, L. Console, P. Terenziani, and D.T. Dupré. A spectrum of definitions for temporal model-based diagnosis. *Artificial Intelligence*, 102(1):39–79, 1998.
5. M. Campos, A. Cárceles, J. Palma, and R. Marín. A general purpose fuzzy temporal information management. In *EurAsia-ICT 2002. Advances in information and communication technology*. ISBN: 3-85403-161-3., pages 93–97, Teherán, Irán, 2002.
6. L. Console, A. Rivolin, and P. Torasso. Fuzzy temporal reasoning on causal models. *International Journal of Intelligent Systems*, 6(2):100–133, 1991.
7. L. Console and P. Torasso. On the co-operation between abductive and temporal reasoning in medical diagnosis. *Artificial Intelligence in Medicine*, 3(6):291–311, 1991.
8. Luca Console, Luigi Portinale, and Daniele Theseider Dupre. Using compiled knowledge to guide and focus abductive diagnosis. *Knowledge and Data Engineering*, 8(5):690–706, 1996.
9. L. Eshelman. *MOLE: A Knowledge-acquisition tool for cover-and-differentiate systems*, pages 27–80. S.Marcus, Kluwer, Boston, 1988.
10. W. Hamscher, L. Console, and J. de Kleer. *Readings in Model-Based Diagnosis*. Morgan Kaufmann, San Mateo, CA, 1992.
11. William J. Long. Temporal reasoning for diagnosis in a causal probabilistic knowledge base. *Artificial Intelligence in Medicine*, 8:193–215, 1996.
12. R. Marín, S. Barro, A. Bosch, and J. Mira. Modeling the representation of time from a fuzzy perspective. *Cybernetics and Systems: an International Journal*, 25:217–231, 1994.
13. J. Palma and R. Marín. Modelling contextual meta-knowledge in temporal model-based diagnosis. In F.V. Harmelen, editor, *Proc. of the 15th European Conference on Artificial Intelligence*, pages 407–411, Lyon, France, 2002. IOSPress.
14. J. Palma, R. Marín, M. Campos, and A. Cárceles. ACUDES: Architecture for Intensive Care Units DEcision Support. In *Conference Proceedings of the second joint EMBS-BMES conference. 1938-1939*. ISBN: 0-7803-7613-, pages 1938–1039, 2002.
15. J. Palma, R. Marín, J.L. Sánchez, and F. Palacios. A model-based temporal abductive diagnosis model for an intensive coronary care unit. In S. Barro and R. Marín, editors, *In Fuzzy Logic in Medicine. Studies in Fuzziness and Soft Computing*, volume 83, pages 205–235, 2002.
16. D.L. Sackett, W.S. Richardson, W. Rosenberg, and R.B. Haynes. *Evidence-Based Medicine. How to Practice and Teach EBM*. Pearson Professional Limited, 1997.
17. G. Schreiber. Pragmatics of the knowledge level, 1992. Ph.D. Thesis.
18. G. Schreiber, H. Akkermans, A. Anjewierden, R. de Hoog, N. Shadbolt, W. Van de Velde, and B. Wielinga. *Knowledge Engineering and Management The CommonKADS Methodology*. The MIT Press, 1999.
19. F. Steimann and K.P. Adlassnig. A fuzzy medical data model. In R. Trappl, editor, *Proceedings of the 12th European Meeting on Cybernetics and Systems Research*, volume 1, pages 271–278, Singapore, 1994.
20. Friedrich Steimann and Klaus-Peter Adlassnig. Clinical monitoring with fuzzy automata. *Fuzzy Sets and Systems*, 61(1):37–42, 1994.