

TESIS DOCTORAL

**Redes bayesianas temporales:  
aplicaciones médicas e industriales**

Severino Fernández Galán

Licenciado en Ciencias Físicas  
por la Universidad Complutense de Madrid

DEPARTAMENTO DE INTELIGENCIA ARTIFICIAL

FACULTAD DE CIENCIAS

UNIVERSIDAD NACIONAL DE EDUCACIÓN A DISTANCIA

Madrid, 2002



UNIVERSIDAD NACIONAL DE EDUCACIÓN A DISTANCIA  
FACULTAD DE CIENCIAS  
DEPARTAMENTO DE INTELIGENCIA ARTIFICIAL

**REDES BAYESIANAS TEMPORALES:  
APLICACIONES MÉDICAS E INDUSTRIALES**

*Por:* Severino Fernández Galán  
Licenciado en Ciencias Físicas  
por la Universidad Complutense de Madrid

*Director de la tesis:* Prof. Dr. Francisco Javier Díez Vegas

*Codirector de la tesis:* Prof. Dr. José Mira Mira



*A mis padres*



## Agradecimientos

Deseo en primer lugar mostrar mi más sincera gratitud a los Profs. Francisco Javier Díez y José Mira, cuya dirección en la presente tesis doctoral ha aportado en todo momento la orientación y guía necesarias para la realización de los objetivos inicialmente marcados.

Doy las gracias a todos y cada uno de los miembros del Departamento de Inteligencia Artificial de la UNED con los que he podido compartir estos últimos años. Ellos son los artífices de un ambiente de compañerismo y trabajo que me siento afortunado de haber podido disfrutar.

Agradezco de manera especial la valiosa colaboración prestada por el Dr. Francisco Aguado y el resto de miembros del Departamento de Oncología Radioterápica del Hospital Clínico Universitario San Carlos de Madrid. Conocer los mecanismos de desarrollo de un cáncer se ha convertido en una tarea amena gracias a la labor del Dr. Aguado, que en poco tiempo se ganó mi amistad y respeto.

El trabajo reflejado en la presente memoria ha sido posible gracias al apoyo económico prestado por la Comisión Interministerial de Ciencia y Tecnología a través de los proyectos TIC97-0604, TIC97-1135-C04-04 y TIC2001-2973-C05-04 en los que he participado bajo la dirección de los Profs. José Mira y Francisco Javier Díez. Del mismo modo, gracias al apoyo de la Secretaría de Relaciones Exteriores del Gobierno de México pude realizar una estancia de tres meses en dicho país bajo la dirección del Dr. Gustavo Arroyo Figueroa (Instituto de Investigaciones Eléctricas, Cuernavaca) y del Prof. Luis Enrique Súcar (Instituto Tecnológico de Estudios Superiores de Monterrey, campus de Morelos). Todavía hoy sigo recordando con cariño mi estancia en el país hermano.

Finalmente, mi agradecimiento más sentido a mis padres y hermano. El esfuerzo que he dedicado a la realización del doctorado no es ni remotamente comparable al cariño constante que de ellos he recibido.



# Resumen

El objetivo principal de la presente tesis doctoral es el desarrollo de un sistema que modele la evolución de la extensión de un cáncer de nasofaringe. Este sistema sirve de ayuda a los oncólogos de una unidad de oncología radioterápica en la determinación del desarrollo alcanzado por este tipo de cáncer en un paciente antes de aplicar la terapia adecuada.

En la parte I de la memoria presentamos el marco conceptual de modelado de conocimiento en que hemos realizado nuestro trabajo. Debido a la naturaleza de los procesos que tienen lugar en el dominio médico del que nos ocupamos, decidimos basarnos en el uso de redes bayesianas con representación explícita del tiempo para la definición de nuestro modelo de crecimiento cancerígeno.

En la parte II, primeramente revisamos los diferentes tipos existentes de redes bayesianas para razonamiento temporal y analizamos las ventajas e inconvenientes de cada uno. Más adelante formalizamos un nuevo método que denominamos *red de eventos probabilistas en tiempo discreto*, el cual resulta adecuado para el modelado de los mecanismos causales de carácter incierto a los que se ven sujetos un conjunto de eventos temporales. Como principal aportación del nuevo método destacamos el uso de diferentes modelos temporales de interacción causal para cada familia de nodos de la red. Estos modelos representan una adaptación para procesos temporales de los modelos canónicos probabilistas tradicionales. Por esta razón decidimos denominarlos *puertas probabilistas temporales*. También incluimos la aplicación de un nuevo algoritmo que permite la factorización de las probabilidades condicionales correspondientes a familias de nodos que interactúan según un modelo de puerta probabilista temporal.

En la parte III describimos NasoNet, un sistema que aplica al dominio de cáncer de nasofaringe el nuevo método para razonamiento temporal con redes bayesianas desarrollado en la parte II. Por otra parte, mostramos el carácter general de las redes de eventos probabilistas en tiempo discreto a través de su aplicación en un dominio industrial: el diagnóstico y predicción de los fallos que ocurren en un generador de vapor de una central termoeléctrica.

La memoria concluye con un resumen de las principales aportaciones realizadas y con una reseña del futuro previsible en nuestras líneas de investigación.



# Índice

<b>I</b>	<b>MARCO CONCEPTUAL</b>	<b>1</b>
<b>1.</b>	<b>Introducción</b>	<b>3</b>
1.1.	Objetivos y metodología . . . . .	3
1.2.	Organización de la tesis . . . . .	4
<b>2.</b>	<b>Estado actual del campo de modelado de conocimiento</b>	<b>9</b>
2.1.	Orígenes históricos . . . . .	9
2.2.	Aspectos metodológicos . . . . .	11
2.3.	Marcos metodológicos para el modelado del conocimiento . . . . .	14
2.3.1.	CommonKADS . . . . .	14
2.3.2.	Protégé . . . . .	18
2.3.3.	Modelado mediante objetos . . . . .	23
<b>3.</b>	<b>Modelado de conocimiento médico en DIAGEN</b>	<b>29</b>
3.1.	Objetivos de DIAGEN . . . . .	29
3.2.	Aplicación en medicina . . . . .	30
3.2.1.	Entidades genéricas definidas en DIAGEN . . . . .	30
3.2.2.	Tareas genéricas definidas en DIAGEN . . . . .	32
3.3.	Aplicación en oncología radioterápica . . . . .	35
3.3.1.	Descripción del problema . . . . .	35

3.3.2. Entidades del dominio . . . . .	36
3.3.3. Relaciones presentes en el dominio . . . . .	41
3.3.4. Descomposición de tareas . . . . .	43
3.3.5. Diagrama inferencial . . . . .	44
3.3.6. Control de las inferencias y conexión con el dominio . . . . .	47
<b>II RAZONAMIENTO TEMPORAL PROBABILISTA</b>	<b>51</b>
<b>4. Redes bayesianas y tiempo</b>	<b>53</b>
4.1. Redes bayesianas . . . . .	53
4.1.1. Métodos generales de inferencia en redes bayesianas . . . . .	54
4.1.2. Modelos canónicos . . . . .	61
4.2. Razonamiento temporal en inteligencia artificial . . . . .	65
4.2.1. Métodos lógicos . . . . .	66
4.2.2. Métodos basados en restricciones temporales . . . . .	69
4.2.3. Métodos probabilistas . . . . .	72
4.3. Representación explícita del tiempo en redes bayesianas . . . . .	74
4.3.1. Formalismos basados en instantes . . . . .	75
4.3.2. Formalismos basados en intervalos . . . . .	76
4.3.3. Formalismos basados en tiempo continuo . . . . .	78
4.3.4. Recapitulación . . . . .	79
<b>5. Redes de eventos probabilistas en tiempo discreto</b>	<b>81</b>
5.1. Tiempo absoluto vs. tiempo relativo . . . . .	82
5.2. Nodo temporal sin padres . . . . .	83
5.3. Nodo temporal con un padre . . . . .	85
5.4. Modelos canónicos y tiempo . . . . .	87

5.4.1. Puerta O probabilista temporal . . . . .	87
5.4.2. Puerta Y probabilista temporal . . . . .	91
5.4.3. Puertas probabilistas temporales con residuo . . . . .	93
5.5. Comparación con RBDs aplicadas a procesos irreversibles . . . . .	94
5.6. Relevancia temporal en REPTDs . . . . .	97
5.7. Ejemplo de aplicación . . . . .	101
5.8. Cálculo eficiente de la probabilidad en puertas MAX probabilistas . .	103
5.8.1. Un nuevo algoritmo para la puerta MAX probabilista . . . . .	105
5.8.2. Estudio experimental . . . . .	110
5.8.3. Otros trabajos relacionados . . . . .	111
<b>6. Implementación de modelos temporales en Elvira</b>	<b>113</b>
6.1. El entorno Elvira . . . . .	114
6.1.1. Edición de redes en Elvira . . . . .	116
6.1.2. Inferencia en Elvira . . . . .	118
6.1.3. Explicación del razonamiento en Elvira . . . . .	119
6.2. Creación de REPTDs en Elvira . . . . .	119
6.2.1. Especificación de nodos temporales en Elvira . . . . .	123
6.2.2. Especificación de los parámetros probabilísticos temporales asociados a un nodo . . . . .	124
<b>III APLICACIONES</b>	<b>131</b>
<b>7. NasoNet, diagnóstico y pronóstico de cáncer de nasofaringe</b>	<b>133</b>
7.1. Redes bayesianas para diagnóstico de cáncer . . . . .	133
7.2. Razonamiento temporal probabilista en medicina . . . . .	134
7.3. Cáncer de nasofaringe . . . . .	135

---

7.4. NasoNet, una REPTD para cáncer de nasofaringe . . . . .	137
7.4.1. Construcción del grafo causal . . . . .	137
7.4.2. Adquisición de los parámetros de la red . . . . .	141
7.4.3. Ejemplo . . . . .	145
7.4.4. Interfaz de NasoNet . . . . .	149
7.4.5. Evaluación de NasoNet . . . . .	159
7.5. Discusión . . . . .	162
<b>8. Diagnóstico y predicción de fallos en un generador de vapor</b>	<b>165</b>
8.1. Modelado del diagnóstico y predicción de fallos en un generador de vapor . . . . .	166
8.2. REPTD para diagnóstico y predicción de fallos en un generador de vapor . . . . .	167
8.2.1. Nuevo modelo causal del dominio . . . . .	171
8.2.2. Obtención de los parámetros de la REPTD . . . . .	173
8.2.3. Ejemplo . . . . .	176
8.3. Discusión . . . . .	177
<b>IV CONCLUSIONES</b>	<b>181</b>
<b>9. Resultados y trabajo futuro</b>	<b>183</b>
9.1. Evolución de la tesis . . . . .	183
9.2. Principales aportaciones . . . . .	185
9.3. Futuras líneas de investigación . . . . .	189

# Índice de figuras

2.1. Estructura inferencial de la estrategia “Divide y vencerás”. . . . .	17
3.1. Jerarquía de clases en DIAGEN. . . . .	31
3.2. Algunas de las relaciones entre entidades en DIAGEN. . . . .	32
3.3. Papeles del dominio de la tarea DIAGNOSTICA, que todavía no ha sido descompuesta en subtareas. . . . .	33
3.4. Descomposición de la tarea DIAGNOSTICA según el Método DIAGEN.	34
3.5. Papeles del dominio en la primera descomposición de tareas. . . . .	34
3.6. Estructura general de una entidad cualquiera del dominio. . . . .	37
3.7. Estructura general de una relación del dominio. . . . .	42
3.8. Descomposición de la tarea <i>Sugiere hipótesis diagnóstica</i> mediante el método bayesiano. . . . .	44
3.9. Subtarea <i>Recoge evidencia</i> . . . . .	45
3.10. Subtarea <i>Propaga evidencia</i> . . . . .	46
3.11. Subtarea <i>Genera hipótesis diagnóstica</i> . . . . .	46
4.1. Ejemplo de red bayesiana. . . . .	55
4.2. Puerta O probabilista con $n$ causas. . . . .	62
4.3. Esquema gráfico del cálculo de la TPC asociada a una puerta MAX probabilista con dos causas y un efecto. . . . .	63

4.4. Esquema gráfico del cálculo de la TPC asociada a una puerta MIN probabilista con dos condiciones y un efecto. . . . .	65
4.5. Posibles relaciones entre dos intervalos. . . . .	72
4.6. Representación gráfica de un modelo dinámico markoviano parcialmente observable. . . . .	73
4.7. Ejemplo de red bayesiana dinámica. . . . .	76
4.8. Valores asociados a un nodo temporal $C$ . . . . .	77
4.9. Posible distribución temporal de los eventos $A$ , $B$ y $C$ de la figura 4.8. . . . .	78
5.1. Red temporal con un padre y un hijo. . . . .	85
5.2. Esquema gráfico del cálculo de la TPC asociada a una puerta O probabilista temporal con dos causas. . . . .	88
5.3. Esquema gráfico del cálculo de la TPC asociada a una puerta O probabilista temporal con dos causas y probabilidades condicionales con decaimiento exponencial. . . . .	89
5.4. Esquema gráfico del cálculo de la TPC asociada a una puerta Y probabilista temporal con dos condiciones. . . . .	91
5.5. Red que modela el proceso de recuperación completa de las heridas producidas en un accidente. . . . .	92
5.6. Red con un padre y dos hijos. . . . .	94
5.7. RBD con nodos memoria, obtenida a partir de la red de la figura 5.6. . . . .	96
5.8. Propagación de instantes de interés en un poliárbol con interacciones disyuntivas y retardos limitados en el tiempo. . . . .	98
5.9. Propagación de instantes de interés a través de una red con bucles. . . . .	99
5.10. Arco con retardos. . . . .	100
5.11. Afueras de una ciudad. . . . .	102
5.12. Grafo auxiliar de la red bayesiana de la figura 4.1. . . . .	109
5.13. Un posible árbol de unión para el grafo de la figura 5.12. Muestra los potenciales asociados a cada clique. . . . .	109

5.14. Tiempo promedio (en segundos) para 50 redes de 25 variables binarias, en función del número de arcos. La propagación se realiza con TPCs generales ( $\diamond$ ) y con puertas MAX factorizadas ( $\circ$ ). . . . . 110

5.15. Tiempo promedio (en segundos) para 50 redes con 10 variables de 5 valores, en función del número de arcos. La propagación se realiza con TPCs generales ( $\diamond$ ) y con puertas MAX factorizadas ( $\circ$ ). . . . . 111

6.1. Pantalla principal del entorno Elvira. . . . . 115

6.2. Ventana para la definición del nombre y del título de un nodo en el entorno Elvira. . . . . 116

6.3. Ventana para la definición de los valores de un nodo en Elvira. . . . . 117

6.4. Tabla de probabilidades condicionales de un nodo en Elvira, cuyos padres son  $A$  y  $B$ . . . . . 117

6.5. Pantalla obtenida en modo inferencia en Elvira. . . . . 118

6.6. Distribución de probabilidad con decaimiento exponencial ( $k = 0.6$ ). . . 121

6.7. Ventana para la definición del rango temporal de un nodo evento. . . 124

6.8. Valores temporales de un nodo evento. . . . . 124

6.9. Ventana para la definición de las probabilidades a priori de un nodo temporal sin padres. . . . . 125

6.10. Definición manual de las probabilidades a priori de un nodo temporal. 126

6.11. Ventana que solicita al usuario un valor de probabilidad que servirá para definir una distribución constante de probabilidad. . . . . 126

6.12. Ventana para la definición de los parámetros temporales de una familia con dos padres. . . . . 127

6.13. Tabla asociada a una familia de nodos temporales que interactúan según un modelo de puerta O probabilista temporal. . . . . 128

6.14. Probabilidades a priori en Elvira para una familia de tres nodos temporales. . . . . 129

7.1. Esquema de la evolución de un cáncer de nasofaringe. . . . . 137

7.2. Parte de la red bayesiana que modela la evolución de un cáncer de nasofaringe. . . . .	141
7.3. Función de densidad de probabilidad para $X_i$ cuando $X_i = x_i[1]$ . . . . .	143
7.4. Función de transferencia de probabilidad entre $X_i$ e $Y$ . . . . .	144
7.5. Función de densidad de probabilidad para $Y$ . . . . .	144
7.6. Subgrafo que forma parte de NasoNet. . . . .	146
7.7. Posibles escenarios a partir de tres hallazgos. . . . .	149
7.8. Parte del grafo de la red bayesiana de NasoNet. . . . .	150
7.9. Pantalla principal de la interfaz de NasoNet. . . . .	152
7.10. Diálogo inicial de NasoNet. . . . .	153
7.11. Ventana para la especificación del período de ocurrencia de un evento. . . . .	154
7.12. Ventana para la definición del rango temporal de tres años. . . . .	156
7.13. Ejemplo de rangos temporales para diagnóstico y predicción, dados los eventos $A$ , $B$ y $C$ . . . . .	157
7.14. Probabilidades a posteriori numéricas para el evento “aparición de anosmia”. . . . .	158
7.15. Pantalla para las gráficas de las distribuciones de probabilidad a posteriori. . . . .	159
8.1. Esquema de la estructura de un generador de vapor de una central termoeléctrica. (Tomado de [6].) . . . . .	168
8.2. Grafo de la RBNT que modela los posibles fallos de un generador de vapor. . . . .	169
8.3. Grafo de la REPTD que modela los fallos en un generador de vapor. . . . .	172
8.4. Rango temporal del ejemplo. . . . .	176

# Índice de tablas

4.1. Composición de relaciones primitivas entre instantes. . . . .	71
4.2. Clasificación de redes bayesianas aplicadas a razonamiento temporal. . . . .	80
5.1. Una TPC general para $t_A=2$ y $t_B=3$ . . . . .	85
5.2. TPC invariante en el tiempo con dos retardos, para $t_A=2$ y $t_B=3$ . . . . .	86
5.3. TPC del arco $A \rightarrow B$ . . . . .	95
5.4. TPC del arco $A \rightarrow C$ . . . . .	95
5.5. TPCs de la RBD asociada al ejemplo. . . . .	96
5.6. TPC de un arco con retardos pero sin instantes de interés. . . . .	101
5.7. TPC de un arco con retardos e instantes de interés. . . . .	101
5.8. Probabilidades a priori de $C_1$ . . . . .	103
5.9. Probabilidades a priori de $C_2$ . . . . .	103
5.10. Parámetros asociados a $P_1$ . . . . .	104
5.11. Parámetros asociados a $P_2$ . . . . .	104
5.12. Parámetros asociados a $P_3$ . . . . .	104
5.13. Probabilidades a posteriori para $P_2 = p_2[9:00]$ . . . . .	105
5.14. Probabilidades a posteriori para $P_1 = p_1[8:30]$ y $P_2 = p_2[9:00]$ . . . . .	105
7.1. Ejemplo de parámetros de un arco $X_i \rightarrow Y$ en NasoNet. . . . .	145
7.2. Parámetros de la red de la figura 7.6. . . . .	147

7.3. Probabilidades a posteriori para tumores vegetantes primarios con localización temporal para cada escenario. . . . .	148
7.4. Nuevas probabilidades a posteriori. . . . .	148
7.5. Porcentaje de eventos correctamente diagnosticados o predichos. . . .	163
8.1. Retardos (en segundos) asociados al arco FBAA $\rightarrow$ ABA para 72 pruebas diferentes en el simulador. . . . .	174
8.2. Probabilidades a posteriori para <i>aba</i> [21]. . . . .	177
8.3. Probabilidades a posteriori para <i>aba</i> [21] y <i>tvS</i> [24]. . . . .	177

# Parte I

## MARCO CONCEPTUAL



# Capítulo 1

## Introducción

### 1.1. Objetivos y metodología

El propósito general del trabajo desarrollado en la presente tesis doctoral ha sido la implementación y evaluación de un sistema basado en conocimiento, que permitiera modelar la evolución de la extensión de un cáncer de nasofaringe de forma análoga a como lo hacen los expertos médicos de una unidad de oncología radioterápica. El conocimiento médico nos lo ha proporcionado el Dr. D. Francisco Aguado Linaza, perteneciente al Servicio de Oncología Radioterápica del Hospital Clínico Universitario San Carlos de Madrid. El desarrollo del trabajo se ha realizado en el contexto de dos proyectos CICYT denominados DIAGEN (TIC97-0604) y Elvira (TIC97-1135-C04-04 y TIC2001-2973-C05-04).

El proyecto DIAGEN nos ha aportado la perspectiva del modelado de conocimiento en términos de componentes reutilizables, a partir de una primera clasificación del conocimiento médico en entidades y relaciones del dominio, por un lado, y en tareas, métodos y control, por otro lado. Las entidades y relaciones se vertebran en una ontología común a un conjunto de especialidades médicas. Nuestro trabajo se ha centrado en las redes causales y en los aspectos temporales de esta ontología para la especialidad de oncología radioterápica.

Tras el modelado en el nivel del conocimiento y en el dominio del observador externo, tenemos que pasar a la fase en la que las entidades y relaciones del modelo se reescriben en términos formales, más próximos al programa. En nuestro caso, tras

valorar la naturaleza del conocimiento existente y el conjunto de alternativas formales a nuestra disposición, hemos seleccionado las redes bayesianas con representación explícita del tiempo<sup>1</sup> como la opción idónea para la representación de conocimiento. De esta forma, enlazamos la ontología del proyecto DIAGEN con el entorno de edición, inferencia y explicación para modelos gráficos probabilísticos desarrollado en el proyecto Elvira.

Finalmente, para ilustrar la validez de nuestra propuesta de modelado y formalización en otros dominios distintos a la medicina, hemos aplicado nuestro formalismo en un dominio industrial. En concreto, hemos construido un sistema de ayuda al diagnóstico y predicción de fallos en un generador de vapor de una central termoeléctrica. Este trabajo lo hemos realizado en colaboración con investigadores pertenecientes al Instituto de Investigaciones Eléctricas de Cuernavaca (México).

## 1.2. Organización de la tesis

La presente memoria de tesis doctoral se estructura en nueve capítulos. Tras este primer capítulo introductorio, en el capítulo 2 planteamos el problema general del modelado de conocimiento y presentamos el estado actual de las distintas alternativas metodológicas y formales. De esta manera, ponemos en contexto nuestro trabajo.

En el capítulo 3 se describen los aspectos fundamentales del proyecto DIAGEN, así como las entidades, relaciones y esquema inferencial básico correspondientes a la especialidad de oncología radioterápica. Al final del capítulo presentamos un resumen de esas entidades (hallazgos, signos, síntomas y síndromes), de sus relaciones de causalidad, de los papeles que las entidades juegan en el razonamiento causal y de las distintas subtarefas existentes.

---

<sup>1</sup>A lo largo de la presente memoria de tesis doctoral consideramos sinónimos los términos *red bayesiana con representación explícita del tiempo* y *red bayesiana temporal*. Por el contrario, el término inglés *temporal Bayesian network* se suele asociar dentro de la comunidad científica internacional a lo que nosotros denominaremos *red bayesiana dinámica* (*dynamic Bayesian network*), que es un tipo particular de red bayesiana para razonamiento temporal. La razón por la que las *redes bayesianas dinámicas* fueron denominadas *temporal Bayesian networks* es que fueron históricamente el primer formalismo que introdujo explícitamente el tiempo en una red bayesiana.

Debido a que hemos decidido basarnos en el uso de redes bayesianas con representación explícita del tiempo para hacer computable el modelo del capítulo 3, en el capítulo 4 repasamos los principales tipos de redes bayesianas para razonamiento temporal anteriores a nuestro trabajo. Hacemos especial énfasis en el modelo de *redes bayesianas dinámicas* y en el de *redes bayesianas con nodos temporales*. El primero de estos formalismos ha sido el más utilizado a lo largo de los últimos años por la comunidad científica en el modelado de procesos temporales sujetos a incertidumbre. El segundo es el formalismo que, a nuestro juicio, presentaba más ventajas de cara a resolver el problema inicial que habíamos abordado en la presente tesis doctoral. Finalmente, ninguno de los formalismos existentes se adecuaba completamente a las necesidades planteadas por el problema que pretendíamos resolver. Esto nos condujo al desarrollo de un nuevo método de razonamiento temporal probabilista que hemos denominado **red de eventos probabilistas en tiempo discreto**. Este tipo de red resulta adecuado para el modelado de los mecanismos causales de carácter incierto que originan un conjunto de eventos temporales.

El capítulo 5 describe las redes de eventos probabilistas en tiempo discreto y las ventajas que este nuevo método aporta al razonamiento temporal mediante redes bayesianas. Entre dichas ventajas destacamos aquí el hecho de permitir el uso de diferentes modelos temporales de interacción causal para cada familia de nodos de la red. (Una familia de nodos está formada por un nodo y sus padres.) Estos modelos constituyen una adaptación para procesos temporales de los modelos canónicos probabilistas tradicionales (puerta O probabilista y puerta Y probabilista, entre otros), por lo que decidimos denominarlos **puertas probabilistas temporales**. A su vez, en este capítulo incluimos un nuevo algoritmo para la factorización de tablas de probabilidades condicionales correspondientes a familias de nodos que interactúan según un modelo de puerta probabilista temporal. Este algoritmo facilita en gran medida la inferencia en redes de eventos probabilistas en tiempo discreto.

En el capítulo 6 describimos brevemente el entorno para la creación de modelos gráficos probabilistas desarrollado dentro del proyecto Elvira por investigadores pertenecientes a varias universidades españolas. Asimismo, detallamos cómo hemos implementado dentro del entorno Elvira las utilidades necesarias para la creación de redes de eventos probabilistas en tiempo discreto. Estas utilidades permiten automatizar en gran medida los aspectos que adquieren mayor complejidad en la definición

de una red de eventos probabilistas en tiempo discreto: introducción de los valores temporales de cada nodo e introducción de los parámetros probabilistas temporales asociados a cada familia de nodos.

Una vez que disponemos del modelo conceptual (capítulo 3) y del modelo matemático en que vamos a basarnos para hacer operacionales sus inferencias (capítulos 4, 5 y 6), en el capítulo 7 llevamos a la práctica nuestro modelo. Como resultado obtenemos el sistema **NasoNet**, que sirve de ayuda al diagnóstico y pronóstico de la extensión de un cáncer de nasofaringe. La metodología empleada en la construcción de NasoNet tiene carácter general. Si bien ha sido aplicada al caso particular de cáncer de nasofaringe, el desarrollo de un modelo para cualquier otro tipo de cáncer se llevaría a cabo de forma análoga. Este capítulo aborda la validación y evaluación de NasoNet distinguiendo entre:

1. La validación del conocimiento y su correspondencia con los elementos del mundo real. Prestamos especial atención al tipo y número de nodos, a la arquitectura de la red y al conocimiento temporal representado.
2. La validación de la implementación en términos de eficiencia y exactitud de los resultados obtenidos.

Finalmente, para poner de manifiesto el carácter general del modelo conceptual de DIAGEN y del modelo bayesiano temporal que lo soporta, los hemos reutilizado en una **aplicación industrial**, tal como se muestra en el capítulo 8. Se trata de la tarea de diagnóstico y predicción de fallos en un generador de vapor de una central termoeléctrica. Los Drs. Arroyo Figueroa y Súcar, de México, ya habían estudiado previamente este dominio, que decidieron modelar mediante un nuevo formalismo al que denominaron *redes bayesianas con nodos temporales*. Precisamente este formalismo fue el que nos sirvió de base para la definición de las redes de eventos probabilistas en tiempo discreto, que posteriormente aplicamos al problema del cáncer. En dicho capítulo reseñamos los resultados de la aplicación de nuestro modelo de redes de eventos probabilistas en tiempo discreto a este dominio industrial y las ventajas que ofrece frente al modelo de redes bayesianas con nodos temporales.

La memoria termina con un capítulo de conclusiones en que hacemos una revisión de la evolución de la tesis, resumimos las principales aportaciones realizadas y

---

discutimos las líneas de investigación que quedan abiertas, tales como el desarrollo de los aspectos temporales del modelo formal y una evaluación más profunda y posterior refinamiento del modelo usado en NasoNet.



## Capítulo 2

# Estado actual del campo de modelado de conocimiento

### 2.1. Orígenes históricos

Los años que siguieron al nacimiento de la inteligencia artificial (en la Conferencia de Darmouth, en 1956) estuvieron caracterizados por el interés en problemas surgidos en dominios llamados *micromundos formales*, que correspondían a simplificaciones muy fuertes del mundo real. En esta época adquirió gran importancia el estudio de materias tales como la demostración automática de teoremas, los juegos entre varios adversarios o la planificación en el mundo de los bloques, entre otros. La forma de abordar este tipo de problemas consistía en realizar procesos de búsqueda en un espacio de estados. Las estrategias de control para guiar la búsqueda en dicho espacio se convirtieron en uno de los temas de mayor interés. Por tanto, en estos años se puso generalmente poco énfasis en el empleo de conocimiento específico sobre el dominio, puesto que cualquier problema quedaba formulado simplemente a partir de la definición de un conjunto de estados, un conjunto de operadores entre los mismos y una determinada estrategia de exploración en el espacio de estados.

La década de los setenta experimentó el apogeo de los llamados *sistemas expertos*. Un sistema experto es un programa de ordenador que imita la forma en que un experto humano resuelve tareas en un dominio real más o menos acotado. Estos dominios se diferencian de los micromundos formales por el mayor volumen de

conocimiento que es necesario modelar. Las características esenciales de un sistema experto son:

- Especialización y competencia en un campo limitado del mundo real.
- Separación del conocimiento representado y del módulo encargado de realizar las inferencias. (Un proceso inferencial permite obtener nuevo conocimiento a partir del que se poseía previamente.)
- Capacidad de explicación del razonamiento y diálogo con el usuario de una forma amigable.

El principal debate al que dieron origen los sistemas expertos fue el de establecer qué método era el más adecuado para representar el conocimiento: lógica, reglas, redes o marcos, entre otros. En general, cada método de representación tenía asociada una forma propia de realizar inferencias. En lugar de optar por un único método, se prefirió estudiar qué combinación de los métodos existentes resultaba conveniente en cada caso concreto. La mayoría de sistemas expertos se construyeron en base a reglas y utilizaban objetos, los cuales comparten muchas de las ideas propuestas por Marvin Minsky para los marcos [95].

En la década de los ochenta, la práctica habitual para la construcción de sistemas basados en el conocimiento consistía en la obtención de un conjunto de reglas. Por medio de tales reglas, el sistema debía imitar la forma en que el experto resolvía un determinado problema. Tal como Clancey [29] hizo notar en su análisis del sistema experto MYCIN [15], el enfoque basado en reglas adolecía de ciertas deficiencias. Por ejemplo, la obtención de un conjunto suficiente de reglas para la resolución de una determinada tarea sólo resulta ser posible cuando la tarea tiene un carácter trivial. Además, una base de conocimientos compuesta por reglas es difícil de mantener y gestionar. La simple adición de una regla puede cambiar el comportamiento del sistema de forma importante.

Una de las ventajas que se atribuían a los sistemas basados en reglas es su supuesta modularidad, gracias a la cual sería posible introducir libremente nuevas reglas en la base de conocimientos, que el motor de inferencia se encargaría de encadenar con el resto de las reglas. Sin embargo, a medida que aumenta el número

de reglas en la base de conocimientos, ésta resulta más difícil de mantener por dos motivos principales. En primer lugar, resulta casi imposible predecir el efecto que va a tener la adición de una nueva regla y comprobar que no va a generar inconsistencias. En segundo lugar, a medida que el número de reglas crece, éstas van perdiendo su carácter declarativo. El diseñador necesita tener en cuenta cómo ordena las reglas en la base de conocimientos y cómo ordena las cláusulas dentro de los antecedente de las reglas.

Progresivamente se llegó al convencimiento más o menos generalizado de que la inteligencia artificial aplicada se había convertido en una especie de “arte”, puesto que no existía un método sistemático y preciso para la construcción de sistemas basados en el conocimiento. No se podía afirmar que existiera una *ingeniería del conocimiento* propiamente dicha.

## 2.2. Aspectos metodológicos

Como posible solución a los problemas que planteaban los sistemas basados en reglas, surgió la idea de describir el comportamiento de un agente racional en un nivel que fuera independiente de cualquier representación simbólica particular. Dicho nivel fue denominado por Newell [99] “nivel del conocimiento”. Este nivel permite describir el razonamiento en términos de objetivos, acciones necesarias para alcanzarlos y conocimiento necesario para llevar a cabo esas acciones.

A partir de la aparición de la hipótesis de Newell sobre la existencia del nuevo nivel de descripción, surgieron diferentes formalismos [22, 30, 110, 125, 135] cuya base residía en el modelado en el nivel del conocimiento. Estos formalismos se caracterizaban por el establecimiento de varios *tipos de conocimiento*, por la introducción de los llamados *papeles del dominio* y por ser fieles al *principio de reutilización* de componentes.

Los sistemas basados en reglas utilizaban una representación plana de un solo nivel. Esta representación no permitía distinguir entre diferentes tipos de conocimiento [29]. Una tendencia bastante generalizada en la actualidad ha sido la clasificación del conocimiento en, al menos, los siguientes tipos:

- Una **tarea** que hay que resolver (diagnosticar una enfermedad, establecer un tratamiento...).
- Un **método de resolución de problemas** para resolver una tarea específica. Generalmente, un método permite descomponer una tarea en subtareas, establecer un flujo de control para la ejecución de las mismas (iteración, bifurcación, etc.) y organizar el flujo de datos en el sistema teniendo en cuenta los papeles del dominio definidos. Dada una tarea, habitualmente es posible encontrar diferentes métodos para la resolución de problemas que permitan llevarla a cabo. La aplicabilidad de un método para resolver un determinado tipo de tarea depende de su competencia para obtener el objetivo de la tarea y de la disponibilidad del conocimiento necesario para alcanzar dicho objetivo. La organización, clasificación y caracterización en bibliotecas de los diferentes métodos para resolución de problemas constituyen una línea de trabajo abierta [50].
- Una **inferencia**, que es una tarea primitiva que no es necesario seguir descomponiendo en nuevas subtareas, ya que representa una función elemental de razonamiento, directamente implementada en el sistema.
- Una **ontología del dominio**, que describe la estructura de las entidades y relaciones presentes en el dominio. Gruber [62] define una ontología como una “especificación formal y explícita de una conceptualización compartida”. Existen ontologías que intentan abarcar el conocimiento válido en medicina [133], otras que se ocupan del propio dominio de modelado de conocimiento [24], etc.

Los sistemas basados en reglas generalmente suponen que, en principio, todo el conocimiento es aplicable en cada paso del proceso de razonamiento. Esto suele reducir la eficiencia computacional del sistema. En el nivel del conocimiento, una forma de evitar este inconveniente consiste en limitar los casos en que el conocimiento puede ser usado. Esto se consigue restringiendo el papel que cada elemento de conocimiento puede jugar en el proceso de inferencia, a través de los llamados **papeles del dominio**. McDermott [92] desarrolló programas capaces de adquirir automáticamente el conocimiento del experto en el dominio. De este modo, surgieron

los denominados *métodos limitadores de papeles*, que guían el proceso de adquisición del conocimiento. Estos métodos especifican los papeles que juegan en cada método los diferentes elementos del conocimiento.

Las representaciones en el nivel simbólico que son dependientes de la implementación no son fácilmente reutilizables en nuevas situaciones. Esto es así debido a que dichas representaciones carecen de una descripción en el nivel del conocimiento que permita identificar componentes genéricos. Precisamente una de las razones para introducir modelos en el nivel del conocimiento es la posibilidad de **reutilizar componentes de modelado**. El intento de construir bibliotecas de componentes reutilizables se da tanto en el nivel del conocimiento de tareas mediante la definición de *tareas genéricas* [20], como en el nivel de entidades del dominio a partir del diseño de *ontologías genéricas* que están especializadas en campos concretos. Un número reducido de tareas genéricas permite cubrir un amplio conjunto de problemas del mundo real.

La fase inicial de desarrollo de un sistema que duplique el conocimiento que un experto posee sobre un dominio particular, consiste en la adquisición del conocimiento. Se diseña un modelo de cómo realiza el experto su tarea (conocimiento inferencial y de tareas) y qué conceptos utiliza (conocimiento del dominio). Por tanto, por un lado se diseña una capa de tareas genéricas y métodos de descomposición de las mismas hasta obtener inferencias y, por otro lado, se crea una capa lo más genérica posible de conocimiento del dominio, haciendo uso de objetos estructurados. En la capa de tareas se descompone cada tarea en subtareas hasta llegar a inferencias elementales, cuyas entradas y salidas deben quedar inequívocamente especificadas a través de los papeles del dominio. Cada descomposición particular de una tarea se debe completar con la definición del flujo de control para la ejecución de las subtareas de las que está compuesta. En la capa de conocimiento del dominio aparecen las entidades y las relaciones del dominio, que se convertirán en las entradas y salidas de las inferencias de la capa de tareas. La función gramatical desempeñada por cada término presente en la descripción en lenguaje natural del conocimiento de un experto ofrece indicios para el establecimiento de jerarquías de entidades y de relaciones. A modo de ejemplo, una relación entre entidades se puede identificar en la descripción en lenguaje natural del conocimiento del experto a partir de un verbo.

## 2.3. Marcos metodológicos para el modelado del conocimiento

A lo largo de los últimos años han surgido un conjunto de marcos de modelado para el diseño y operacionalización de modelos en el nivel del conocimiento. A continuación describimos algunos de estos marcos que, aunque generalmente se basan en principios metodológicos similares (que ya han sido descritos en la sección previa), mantienen ciertas diferencias de orientación.

### 2.3.1. CommonKADS

CommonKADS [119, 131, 135] constituye una metodología diseñada para la creación de sistemas basados en el conocimiento, que abarca además todo el ciclo de desarrollo del software. Más que un marco rígido de modelado, CommonKADS ofrece un conjunto de principios integrable con otros entornos o herramientas. La metodología CommonKADS sigue una técnica para la construcción de sistemas basados en el conocimiento consistente en construir por separado una serie de modelos que capten las características más sobresalientes de un sistema y su entorno. Existen seis tipos diferentes de modelos:

1. *Modelo de organización*: permite analizar la organización en la que el sistema basado en el conocimiento va a ser introducido.
2. *Modelo de tareas*: se usa para describir las tareas generales que serán realizadas dentro del entorno organizativo en el que el sistema basado en el conocimiento operará, además de proporcionar el marco adecuado para la distribución de dichas tareas entre un conjunto de agentes.
3. *Modelo de agentes*: cada agente ejecuta una tarea. Puede ser un humano, un ordenador o cualquier otra entidad capaz de ejecutar una tarea. Este modelo describe las capacidades y características de los agentes.
4. *Modelo de comunicación*: especifica el modo de intercambio de información entre diferentes agentes implicados en la ejecución de las tareas descritas en el modelo de tareas.

5. *Modelo de pericia*: constituye el punto de interés principal en la metodología CommonKADS. Modela el conocimiento que utiliza un agente para resolver una tarea. El *modelo de pericia* distingue entre el conocimiento que se tiene sobre el dominio y el conocimiento que indica cómo llegar a la resolución de un problema. Este modelo se subdivide en tres niveles: el nivel del dominio (conocimiento declarativo del dominio), el nivel inferencial (una librería de estructuras de inferencia genéricas) y el nivel de tareas (orden de ejecución de las inferencias).
6. *Modelo de diseño*: mientras que el resto de modelos tienen que ver con el análisis de un sistema basado en el conocimiento, éste se ocupa del diseño del mismo de cara a obtener una implementación.

CommonKADS no requiere la utilización de entornos o lenguajes específicos ni dispone de herramientas para la adquisición automática de conocimiento. No presupone la utilización de un método particular de representación de conocimiento. El diseño de un modelo de pericia según esta metodología consiste en la descomposición de tareas en subtareas, la asignación de métodos para la resolución de problemas a cada subtarea hasta llegar al nivel de inferencias primitivas en la biblioteca de componentes y, finalmente, el enlace con el dominio a través de los papeles definidos. Las conexiones entre las subtareas se llevan a cabo a través de los papeles del dominio.

A continuación analizamos con un grado de detalle mayor cada uno de los niveles que componen el modelo de pericia de CommonKADS.

### **Modelo de pericia de CommonKADS**

El modelo de pericia de CommonKADS es un modelo del grado de competencia requerido para realizar una determinada tarea. Este modelo consta de tres componentes: el conocimiento declarativo sobre el dominio, los procesos inferenciales necesarios para la resolución de problemas y, por último, una estructura de tareas que indique la descomposición jerárquica y el orden de los procesos inferenciales.

**NIVEL DEL DOMINIO:** CommonKADS clasifica los elementos del conocimiento del dominio en cuatro categorías:

**Conceptos:** clases de objetos del dominio estudiado.

**Propiedades:** atributos de conceptos (por ejemplo “tamaño”).

**Expresiones:** afirmaciones de la forma “la *propiedad* de *concepto* es *valor*”.

**Relaciones:** enlaces entre dos elementos cualesquiera del conocimiento del dominio.

Una vez que cada elemento del conocimiento del dominio ha sido clasificado, se puede usar en los llamados *modelos de dominio*, los cuales muestran relaciones entre diferentes elementos de conocimiento. Por ejemplo, un modelo de dominio podría mostrar cada uno de los casos existentes en el dominio en que un concepto “causa” otro, podría mostrar una jerarquía de conceptos conectados por la relación “es-un-tipo-de”, podría conectar ciertos síntomas que aparecen en un sistema con las posibles anomalías que explicarían dichos síntomas, etc. De cara a poder reutilizar modelos de dominio en diferentes problemas, CommonKADS recomienda ampliar la representación del conocimiento del dominio hasta llegar a un nivel superior de abstracción. Este nivel contendría afirmaciones genéricas sobre la estructura y contenidos de los modelos de dominio. De esta manera, generaríamos lo que llamamos *ontología del modelo*.

En definitiva, en el modelo de pericia de CommonKADS el conocimiento del dominio consta de la ontología del dominio y de un conjunto de modelos de dominio. Los modelos de dominio representan relaciones entre los elementos de la ontología del dominio. Por otra parte, es conveniente la creación de una perspectiva abstracta y genérica del conocimiento del dominio mediante la denominada ontología del modelo.

**NIVEL INFERENCIAL:** El nivel inferencial se ocupa de la forma en que un problema puede ser resuelto. Esta información se representa por medio de las denominadas *estructuras inferenciales*, que son diagramas que muestran cómo conectar una serie de inferencias primitivas y papeles del dominio para poder resolver un cierto problema. CommonKADS proporciona una librería de estructuras inferenciales genéricas, clasificadas por el tipo de tarea que resuelven (clasificación, diagnóstico, etc.). Estas estructuras inferenciales genéricas pueden constituir el punto de partida para el desarrollo de la estructura inferencial de una aplicación particular.

Un ejemplo de estructura inferencial es el mostrado en la Figura 2.1. En esta estructura se analiza el proceso de resolución de un problema que puede ser descompuesto en un conjunto de subproblemas cuya solución es conocida.

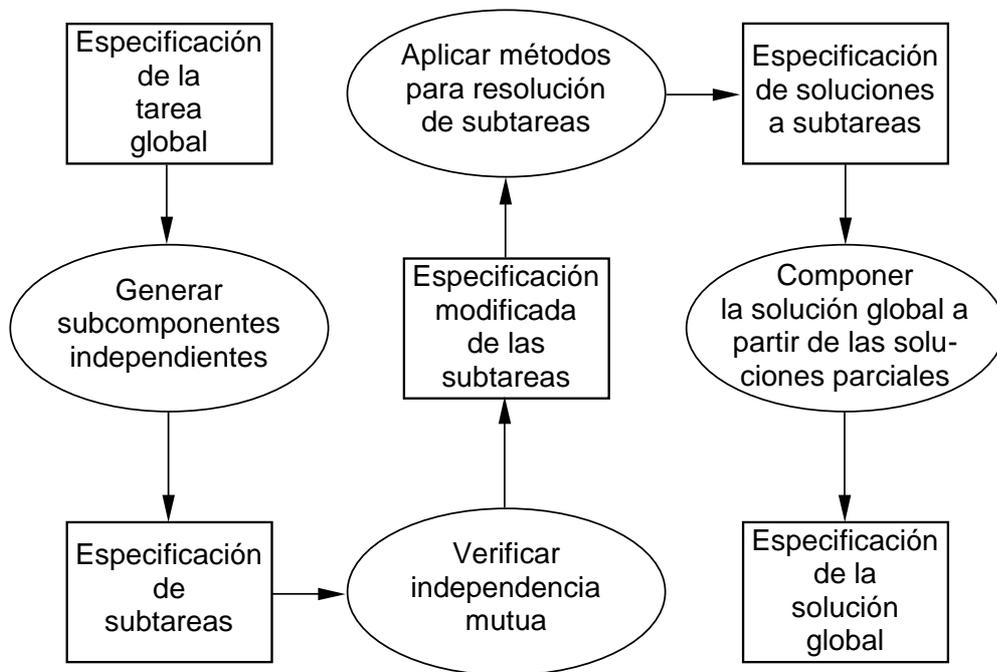


Figura 2.1: Estructura inferencial de la estrategia “Divide y vencerás”.

Los papeles del dominio se suelen representar mediante rectángulos, las inferencias mediante óvalos y se utilizan flechas para conectar papeles e inferencias. Existen representaciones gráficas especiales que, por ejemplo, denotan que una inferencia se expande en una nueva estructura que detalla las características de la inferencia inicial, o que un papel del dominio es estático, es decir, el conocimiento que representa no varía durante el proceso de resolución del problema.

**NIVEL DE TAREAS:** El nivel de tareas del modelo de pericia se representa normalmente mediante un grafo jerárquico. Cada tarea es descompuesta en varias subtareas mediante la aplicación de algún *método de resolución de problemas*. Existe un conjunto de tareas genéricas predefinidas en CommonKADS.

### 2.3.2. Protégé

Protégé es una aplicación que ha evolucionado durante más de una década, pasando de ser un simple programa de ayuda en la construcción de bases de conocimientos en un dominio especializado, a un conjunto de herramientas para la creación y mantenimiento de bases de conocimientos de propósito general. Aunque en principio se diseñó para un dominio médico (planificación de terapia basada en protocolos), ha crecido hasta convertirse en un conjunto de utilidades de propósito general para la construcción de sistemas basados en el conocimiento.

A mediados de la década de los ochenta, el modelado del conocimiento de un experto consistía en un proceso tal que el diseñador participaba en todas y cada una de sus etapas: debía familiarizarse con el problema, encontrar las estrategias seguidas por los expertos para resolverlo, identificar los conceptos relevantes, definir una estructura inferencial para el sistema resultante y procurar que este sistema fuera lo más genérico y reusable posible.

El objetivo inicial de Protégé fue disminuir el cuello de botella del proceso de adquisición de conocimiento [64] mediante la reducción del papel del diseñador en el proceso de construcción de la base de conocimientos. Para ello, el conocimiento adquirido en una etapa era usado para generar herramientas de adquisición de conocimiento para etapas posteriores.

En un principio, la aplicabilidad de Protégé era limitada ya que fue construido para ser aplicado a un dominio muy específico. A lo largo de más de una década y varias versiones sucesivas, Protégé se ha convertido en una herramienta de propósito general, que sigue centrándose, al igual que la herramienta original, en el uso de metaconocimiento para la creación de herramientas para la adquisición de conocimiento.

#### **Antecedentes y primera versión de Protégé**

Después del éxito inicial de MYCIN, empezó a ser desarrollado ONCOCIN (ONCOlogic myCIN), un sistema consejero para la elaboración de terapias basadas en protocolos para enfermedades cancerígenas. En [124] se discute la relación existente entre MYCIN y ONCOCIN.

ONCOCIN fue construido siguiendo las fases típicas de identificación, conceptualización, formalización, implementación, evaluación y revisión, en cada una de las cuales debía participar el ingeniero de conocimiento. Muy pronto ONCOCIN fue dotado de un nuevo componente para la adquisición de conocimiento denominado OPAL. El objetivo de OPAL era permitir al experto introducir conocimiento sobre el dominio sin necesidad de intervención del diseñador. De esta manera, la fase de implementación se desarrollaba de forma automática. OPAL hacía posible que un oncólogo pudiera introducir directamente en ONCOCIN protocolos de cáncer rellenando una serie de formularios, en vez de tener que generar un conjunto de reglas. Por tanto, OPAL traducía la información introducida por el experto a la representación interna de ONCOCIN.

La arquitectura de OPAL sugería de forma implícita una división cualitativa del tipo de información requerida por un sistema basado en el conocimiento. Además de instancias de conceptos específicos del dominio, obtenidas de los expertos, existía un conjunto de conceptos incorporados de antemano en OPAL, que eran comunes a otros dominios médicos.

Protégé surgió como un intento de generalizar la arquitectura OPAL/ONCOCIN al incluir herramientas para la definición de conceptos y posterior generación de utilidades adicionales para la adquisición del conocimiento del dominio. Las primeras versiones de Protégé consiguieron reducir las barreras existentes en el proceso de adquisición de conocimiento para sistemas consejeros en medicina; no obstante, las bases de conocimientos de estos sistemas no eran realmente muy reusables. Por tanto, se había trasladado el problema del cuello de botella desde el proceso de adquisición de conocimiento al de reutilización de ese conocimiento.

## **Protégé-II**

Los primeros intentos de dotar a un sistema experto de una cierta capacidad de reutilización se basaron en el uso de motores de inferencia de propósito general [134]. (Mientras que el conocimiento del dominio podía quedar desfasado en poco tiempo, era menos probable que los algoritmos de inferencia cambiaran.) También la base de conocimientos de MYCIN fue adaptada para servir de sistema tutor a estudiantes de medicina [28]. Este trabajo se basó en la idea de la existencia de

diferentes tipos o niveles de reglas en un sistema experto: algunas reglas tenían que ver con conceptos del dominio, otras hacían referencia exclusivamente a otras reglas (metarreglas), otras servían para propósitos de explicación del razonamiento, etc.

En el período en que la primera versión de Protégé fue desarrollada, se empezó a sugerir la idea de la creación de bibliotecas de algoritmos para inferencia, que fueran reutilizables en diferentes aplicaciones [92, 135]. En la primera versión de Protégé, las bases de conocimientos estaban orientadas a tareas inferenciales muy específicas. Por el contrario, mediante la separación del conocimiento inferencial se esperaba poder aumentar el grado de reutilización del sistema. Para ello fue necesario modificar la versión original de Protégé.

Protégé inició un proceso de separación explícita del método de resolución de problemas frente al conocimiento del dominio, lo cual dio origen a la aparición de las primeras bibliotecas de métodos. Dicha separación motivó la necesidad de transformar el conocimiento del dominio a una representación que permitiera su manipulación por los métodos para la resolución de problemas. Esta tarea de traducción originó el desarrollo de MODEL (un lenguaje formal para representar el conocimiento del dominio), así como la aparición del concepto de *asociaciones*, que definen la relación entre el conocimiento del dominio y los métodos para la resolución de problemas. Por tanto, los métodos, las tareas y las ontologías del dominio no son tan genéricas como sería deseable y es necesario adaptar los métodos al conocimiento del dominio y viceversa.

Según el nuevo método de construcción de un sistema a través de Protégé-II, debe existir una forma de conectar los métodos de resolución de problemas con el conocimiento del dominio. Para ello se definió una *ontología del método* según la cual un método consta de un algoritmo y un conjunto de definiciones de clases que sirve para delimitar el tipo de datos de entrada y salida del algoritmo. Una asociación consiste en una especificación declarativa de una posible transformación de los conceptos del dominio de acuerdo con la ontología del método. Por tanto, las instancias de la base de conocimientos se transforman en instancias que cierto método de la resolución de problemas puede usar.

En resumen, Protégé-II constituyó un intento de hacer las bases de conocimientos más reusables por medio de la separación de las mismas del conocimiento relacionado

con la forma de resolver problemas. La técnica que se adoptó para ello consistió en el modelado formal de métodos de resolución de problemas y en la posterior utilización de la ontología del método para definir las llamadas asociaciones. El concepto de método de resolución de problemas fue de gran utilidad en la formalización del conocimiento de control en sistemas basados en el conocimiento de grandes dimensiones. Protégé-II fue desarrollado en Estados Unidos al mismo tiempo que la metodología KADS cobraba popularidad en Europa. Mientras que KADS se ocupaba de todo el ciclo de ingeniería del software, Protégé-II se concentró principalmente en el desarrollo de lo que en KADS se denominaba “modelo de pericia”. Una diferencia importante entre las dos metodologías residía en que en Protégé-II el modelo de pericia intervenía en el propio diseño del sistema.

### **Protégé/Win**

El siguiente paso en la evolución de Protégé consistió en pasar de ser ejecutado exclusivamente en estaciones de trabajo NeXT a basarse en el sistema Windows. Los principales cambios introducidos estaban encaminados a dotar a las bases de conocimientos de una estructura más modular. En definitiva, se pretendía hacer que las bases de conocimientos fueran más reusables y fáciles de mantener, estructurándolas en varios componentes modulares en los que unos módulos contenían a otros. La necesidad de bases de conocimientos modulares se derivaba del hecho de que la mayoría de las que habían sido construidas durante los primeros diez años de vida de Protégé compartían un alto porcentaje de los conceptos del dominio que manejaban. Por ejemplo, en la mayoría de bases construidas a partir de dominios médicos aparecían nociones como paciente, enfermedad, medicamento, síntoma, etc.

La partición en varios componentes del conjunto de conceptos o clases manejados por el sistema, cada uno de los cuales podía ser incluido en otra ontología de clases de otro sistema diferente, aportó una serie de beneficios: facilitó la reutilización de conceptos o clases, facilitó la construcción y mantenimiento de bases de conocimientos grandes a partir de otras más pequeñas y permitió a los expertos un mejor entendimiento de los contenidos almacenados.

Protége/Win fue desarrollado al mismo tiempo que surgía el proyecto Common-KADS en Europa.

## Protégé-2000

Protégé-2000 es el nombre de la plataforma actual de Protégé. En las versiones anteriores aparecían una serie de deficiencias que se agudizaban cuando la base de conocimientos crecía por encima de un cierto límite. Por un lado, el lenguaje MODEL no era lo suficientemente flexible para muchos dominios. Por otro lado, la operación conjunta con otros entornos de modelado era muy limitada debido a las dificultades en la traducción de las bases de datos construidas en MODEL a otros lenguajes, incluso a los que estaban basados en marcos. Este último problema se trasladaba también al proceso de edición y manipulación del conocimiento, que dependía de la herramienta utilizada.

Protégé-2000 incorpora el modelo de representación de conocimiento OKBC (*Open Knowledge Base Connectivity*) [26]. OKBC se define a partir de la lógica matemática y constituye un protocolo para sistemas basados en marcos que, con respecto a MODEL, dota a Protégé de una mayor expresividad y facilidad de reutilización.

El modelo de conocimiento de Protégé-2000 utiliza marcos como elemento principal en la construcción de una base de conocimientos. Una ontología en Protégé consta de:

- **Clases e instancias.** Las clases se agrupan en una jerarquía. Si una clase  $B$  es una subclase de otra clase  $A$ , cada instancia de  $B$  lo será también de  $A$ . Protégé incorpora herencia múltiple, de modo que una clase puede tener más de una superclase. El nodo raíz de la jerarquía de clases se denomina :THING. Una clase puede actuar como instancia de otra clase; tal es el caso de las instancias creadas a partir de las llamadas “metaclases”. Una metaclass actúa como patrón para la definición de nuevas clases.
- **Campos.** Los campos describen propiedades de clases e instancias. Cada campo se representa por medio de un marco y se definen independientemente de cualquier otra clase. Cuando se asocia o inserta un campo en una clase, éste podrá almacenar un determinado valor.
- **Facetas.** Constituyen un modo de definir restricciones sobre los valores que puede tomar un campo: su número, su tipo, sus cotas, etc.

### 2.3.3. Modelado mediante objetos

Las metodologías de modelado descritas en las secciones previas presentan una serie de deficiencias desde el punto de vista del campo de la ingeniería del software (consúltese el capítulo segundo de [88] para una discusión detallada). En primer lugar, los modelos resultantes no tienen un carácter formal y preciso, a pesar de la existencia de notaciones específicas para la definición, refinamiento, verificación y validación de los mismos [120, 132]. De hecho, el modelo de pericia ha sido criticado en ese sentido y por la escasa ayuda que ofrece en el proceso de desarrollo de un sistema [52]. Aunque en los últimos años han aparecido trabajos encaminados a aumentar la base formal del modelo de pericia [11, 51, 80], los resultados obtenidos han conducido a la aparición de una serie de herramientas cuya complejidad hace difícil su difusión fuera de entornos de investigación.

En segundo lugar, el nivel inferencial y de tarea corresponde a una descripción de carácter funcional de la forma en que un experto resuelve un problema. Aunque las metodologías tipo CommonKADS propugnan la autonomía de la etapa de análisis frente a etapas posteriores del ciclo de desarrollo del software y la utilidad de sus resultados con independencia del lenguaje utilizado en la etapa de implementación, lo cierto es que un análisis de tipo funcional está inevitablemente orientado a la programación procedimental tradicional.

En tercer lugar, es cuestionable la conveniencia de la división tarea-método-dominio, que obliga a introducir en la arquitectura nuevos elementos para gestionar las interdependencias entre los diferentes componentes reutilizables. De este modo, la arquitectura final resulta demasiado compleja y poco práctica.

Finalmente, el paradigma funcional es insuficiente para modelar el conocimiento de un experto humano. Dicho paradigma identifica el razonamiento humano como un proceso de transformación de datos y de flujo de información entre procesos. Así, Chandrasekaran considera la “sistematización de la ingeniería de conocimiento en términos de tareas” como un modo de experimentar con “teorías funcionales de la inteligencia” [21], dejando de lado otros modelos más afines a los principios de la dinámica cerebral, que son el fundamento de los enfoques conexionistas. La metáfora de Marvin Minsky de la mente como sociedad de agentes cooperativos [96] describe en esencia estos modelos, donde el razonamiento emerge de la interacción y comu-

nicación entre procesos y fuentes de conocimiento. Gran variedad de paradigmas de reconocido interés y difusión, tales como los agentes inteligentes y las arquitecturas de pizarra, entre otros, comparten la base de esta perspectiva. La integración de funcionalidad y datos en entidades autónomas, que constituye la base de estos modelos, se ajusta a una descripción en el marco del análisis orientado a objetos, centrado en la descripción de un dominio de conocimiento y no en los requisitos funcionales de un único problema. El paradigma orientado a objetos se centra en identificar objetos presentes en el dominio de aplicación, a los que posteriormente se asocian una serie de procedimientos. Por tanto, los objetos son entidades autónomas que integran datos y funcionalidad.

Hasta hace un par de décadas, la metodología funcional de desarrollo de software tuvo una mayor aceptación, centrándose en la especificación y descomposición de la funcionalidad de un sistema. Partiendo de un proceso que representa el propósito general del software en desarrollo, se procedía a una división recursiva de ese proceso hasta la obtención de pequeños procedimientos, fáciles de implementar. Los diagramas de flujo constituían la estructura primaria de modelado. Una de las razones de la aceptación de las aproximaciones funcionales fue el predominio de los lenguajes de programación procedimentales. Además, las metodologías basadas en flujos de datos constituyen las primeras aproximaciones formales al desarrollo de software. En estos últimos años, por el contrario, las tecnologías basadas en orientación a objetos se han impuesto gradualmente en el análisis, diseño e implementación de productos software.

En los desarrollos de software orientados a objetos, se procede de forma diferente a las metodologías orientadas a funciones. Las técnicas orientadas a objetos organizan el conocimiento del dominio en torno a objetos, reales o conceptuales, que el cliente transmite en su especificación de requisitos. Las metodologías orientadas a objetos no son simples técnicas de programación sino guías para el modelado abstracto de problemas. Este modelado es independiente de conceptos relacionados con la implementación [32, 115]. Diversos estudios muestran que los análisis orientados a objetos, al contrario que los procedimentales, proporcionan representaciones que están más influidas por el conocimiento del problema que por los detalles de implementación [25, 34, 83, 114].

Conviene reseñar que las raíces del paradigma de orientación a objetos se en-

cuentran en parte dentro del campo de la inteligencia artificial. La idea de marco de Marvin Minsky [95] incluía ya la integración del concepto de “procedimientos adjuntos” en una perspectiva declarativa. Diversos lenguajes para la representación de conocimiento, basados en marcos, evolucionaron a partir de esta idea [14, 53, 113]. Por otra parte, los conceptos relacionados con la orientación a objetos se han introducido progresivamente en el mundo de la inteligencia artificial a través de los lenguajes lógicos, enriqueciendo en particular los lenguajes lógicos concurrentes [39], y a través de los lenguajes basados en reglas tales como Goldworks y Kappa, a los que han aportado los beneficios de la modularidad y encapsulación de datos. El tipo de modularidad que impone un paradigma de descomposición funcional no es fácilmente trasladable a programas escritos dentro del campo de la inteligencia artificial y basados en el empleo de lógica o reglas.

### **Ventajas generales del paradigma orientado a objetos**

En el campo de la ingeniería del software se considera actualmente que, frente al análisis funcional, el análisis orientado a objetos proporciona diseños más estructurados, sistemas más sencillos de manejar y componentes más fácilmente reutilizables.

Las descripciones que resultan de un análisis orientado a objetos son al mismo tiempo parte de la propia solución. En las metodologías orientadas a objetos, la evolución desde el análisis hasta el diseño representa una expansión progresiva de un modelo abstracto inicial. Un objeto de la etapa de diseño es una ligera extensión de una noción de objeto de la etapa de análisis. Normalmente, cuando se genera código por refinamiento sucesivo de un modelo de análisis, no se puede garantizar la eficiencia de la implementación resultante. Este problema no se plantea cuando el ciclo de desarrollo desde el análisis hasta la implementación es orientado a objetos.

El enfoque funcional, al ser la forma más directa de implementar una aplicación determinada, da como resultado un producto poco robusto, que soporta mal el cambio de los requisitos. La mayoría de los cambios en los requisitos se traducen en cambios en funciones, lo cual causa un fuerte impacto en la estructura de los diseños basados en procedimientos. Por el contrario, el enfoque orientado a objetos se centra primordialmente en identificar objetos presentes en el dominio de aplicación, a los que posteriormente se acoplan procedimientos. De este modo, los diseños obtenidos

son más flexibles y extensibles, y permiten la adición o modificación de operaciones a la vez que se mantiene intacta la estructura básica de objetos. Por otro lado, el resultado de la descomposición de un proceso en subprocesos es relativamente arbitrario, de modo que frecuentemente distintos analistas producen descomposiciones diferentes. En los diseños orientados a objetos sucede lo contrario, ya que la descomposición se basa en objetos del dominio y diseñadores diferentes tienden a definir objetos similares. El hecho anterior incrementa las posibilidades de reutilización.

En inteligencia artificial existen técnicas formales orientadas a la verificación de sistemas basados en el conocimiento [61, 94, 108]. Sin embargo, rara vez estos sistemas han sido verificados de acuerdo a una especificación explícita de requisitos por parte del usuario [93]. Por el contrario, habitualmente se ha intentado detectar errores de coherencia, redundancia, circularidad, objetivos inalcanzables o reglas que no se disparan.

En resumen, existe el riesgo, desde el punto de vista de la ingeniería del software, de que los enfoques actuales basados en el modelo de pericia de CommonKADS se muestren demasiado enmarañados y complejos como para alcanzar una difusión amplia. Por el contrario, un enfoque basado en el empleo de técnicas y herramientas bien conocidas y orientadas a objetos tendría a priori mayor probabilidad de éxito.

### **Reutilización de conocimiento según un enfoque orientado a objetos**

A pesar de que la perspectiva funcional pueda parecer más intuitiva que la orientada a objetos, está menos adaptada a la reutilización. La propuesta de diseño de bibliotecas de componentes en la línea sugerida por CommonKADS supone la definición de elementos reutilizables en diferentes niveles (dominio, tarea e inferencia) desacoplados entre sí. La reutilización implica un complejo proceso de selección y adaptación de elementos de diferentes bibliotecas cuyo acoplo está sujeto a fuertes restricciones, particularmente cuando la reutilización tiene lugar en el nivel de implementación [50]. La unificación de funcionalidad y datos, la formalización del concepto de interfaz y el polimorfismo que supone el paradigma de orientación a objetos, resuelven este problema.

Las consideraciones sobre la reutilización forman parte integral de los enfoques orientados a objetos. De ahí que las bibliotecas de clases hayan tenido un uso in-

tensivo desde hace cierto tiempo. Por lo que respecta a los enfoques de reutilización más recientes, cabe destacar la aparición en la última década del concepto de *patrón orientado a objetos* [60], comúnmente definido como “una solución práctica a un problema general”, y el desarrollo de bibliotecas de patrones para las etapas de análisis, diseño e implementación [54, 60].



## Capítulo 3

# Modelado de conocimiento médico en DIAGEN

El origen del trabajo desarrollado en la presente tesis doctoral vino marcado por nuestra participación en el proyecto DIAGEN (TIC97-0604).

### 3.1. Objetivos de DIAGEN

Tal como su propio título indica, el objetivo del proyecto “DIAGEN: un entorno para la reducción a los niveles simbólico y conexionista de modelos genéricos de conocimiento médico en diagnóstico y planificación de terapias” era la creación de un entorno para la reducción de patrones genéricos de conocimiento médico en las tareas de diagnóstico y planificación de terapias, desde su formulación en lenguaje natural hasta sus correspondientes modelos en los niveles simbólico o conexionista. Esta propuesta inicial de carácter general se aplicó posteriormente a los dominios médicos de oftalmología, urología, oncología médica y oncología radioterápica, con la colaboración de especialistas pertenecientes al Hospital General de Galicia y al Hospital Clínico Universitario San Carlos de Madrid.

El proyecto DIAGEN se integra en la línea de investigación iniciada por Clancey [30, 31] y Chandrasekaran [19, 20, 23] consistente en la reutilización de un conjunto de tareas genéricas y de los métodos para llevarlas a cabo. En consecuencia, un sistema basado en el conocimiento puede ser construido partiendo de cero, pero

debería constar de un conjunto de componentes probados y validados en el pasado. Esta propuesta experimentó un gran auge gracias a los proyectos KADS (I y II) [12, 13, 127, 135], una de cuyas propuestas fue el uso de ontologías explícitas para el desarrollo de sistemas basados en el conocimiento [133].

## 3.2. Aplicación en medicina

### 3.2.1. Entidades genéricas definidas en DIAGEN

Para que la reutilización del conocimiento médico sea factible, es esencial poder compartir ontologías que describan el conocimiento del dominio en medicina. Una ontología define un conjunto de términos generales, como enfermedad, hallazgo, tratamiento, etc. La mayoría de los trabajos de creación de ontologías generales en medicina se han realizado fuera del campo de la inteligencia artificial.

Como resultado de una serie de entrevistas realizadas con profesionales pertenecientes a cuatro especialidades médicas diferentes, se definió dentro del proyecto DIAGEN un conjunto genérico de entidades o términos médicos. Algunos de ellos son los siguientes:

**Síntoma:** cada una de las manifestaciones subjetivas de enfermedad, que son observables por el propio enfermo.

**Anamnesis:** diálogo dirigido por el médico para la obtención de los síntomas del enfermo y sus antecedentes.

**Exploración física:** exploración llevada a cabo directamente por el médico.

**Signo:** fenómeno objetivo en el curso de la enfermedad y que el médico reconoce o provoca durante la exploración física.

**Exploración complementaria:** conjunto de pruebas no realizadas directamente por el médico.

**Observación:** determinación cuantitativa o cualitativa de una magnitud, o de la presencia o ausencia de algo en el paciente.

**Hallazgo:** cualificación relevante del resultado de una prueba.

**Proceso fisiopatológico:** alteración orgánica.

**Síndrome:** conjunto de signos y síntomas que existen al mismo tiempo y que definen un proceso fisiopatológico, generalmente de causa desconocida. (Cuando se conoce la causa, se suele hablar de enfermedad.)

**Diagnóstico de extensión:** determinación de la graduación y extensión de una enfermedad, que permite establecer una acción terapéutica.

**Acción terapéutica:** conjunto de medios y métodos que se ponen en práctica para la curación o alivio de las enfermedades.

La figura 3.1 muestra la clasificación jerárquica de los términos anteriores. Cada nodo del árbol resultante representa una entidad del dominio y cada arco está asociado a una relación “es un tipo de”. La raíz del árbol está ocupada por la entidad más general posible, a la que hemos denominado “Entidad del dominio”.

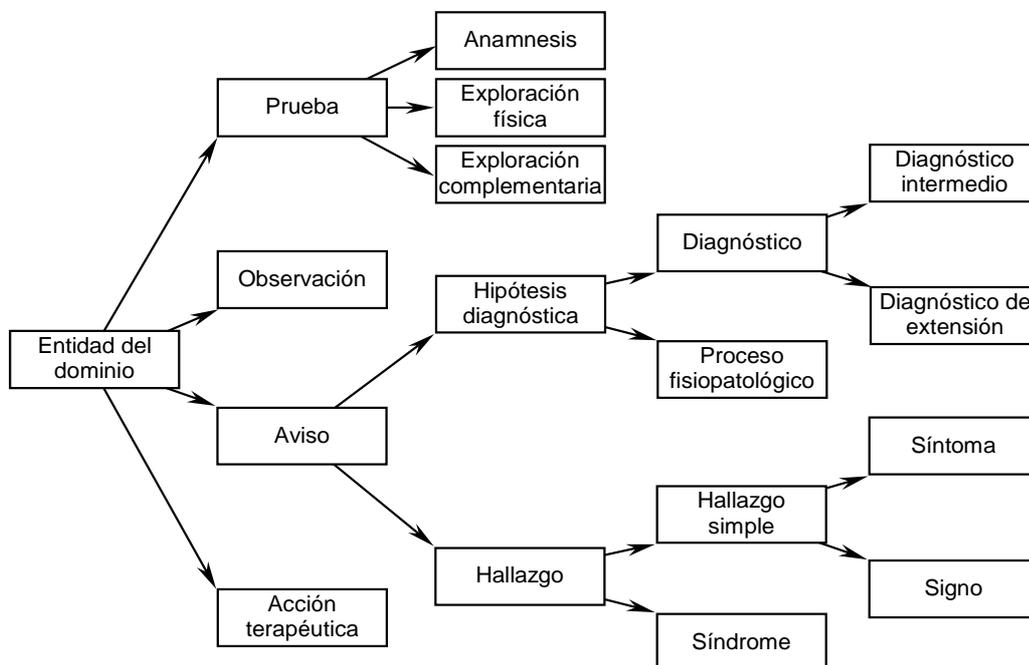


Figura 3.1: Jerarquía de clases en DIAGEN.

Las relaciones entre las entidades del dominio se obtienen también de la descripción en lenguaje natural del conocimiento médico. La figura 3.2 muestra algunas de las relaciones genéricas obtenidas en DIAGEN.

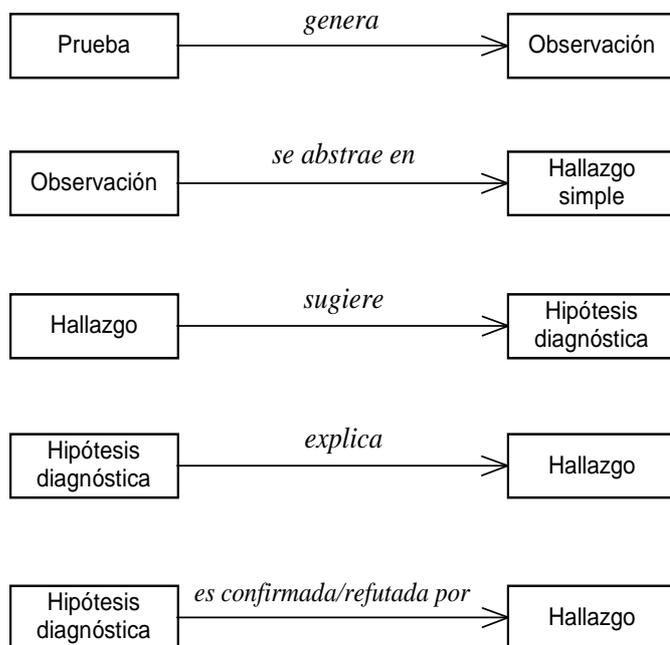


Figura 3.2: Algunas de las relaciones entre entidades en DIAGEN.

### 3.2.2. Tareas genéricas definidas en DIAGEN

Algunos autores [111] clasifican el conjunto de tareas médicas en tres grandes grupos: diagnóstico, planificación de terapia y monitorización. DIAGEN se ocupa exclusivamente del modelado en el nivel del conocimiento de las tareas de diagnóstico y planificación de terapia. Concretando aún más, el trabajo desarrollado en la presente tesis doctoral se centra únicamente en el estudio de la tarea de diagnóstico en oncología radioterápica.

No es fácil establecer una definición única de la palabra “diagnosticar”. Puede consistir en determinar los mecanismos causales de una enfermedad o simplemente en clasificar un conjunto de hallazgos. La primera de tales definiciones es la que tiene mayor sentido en el caso de las enfermedades cancerígenas.

El papel de entrada a todo diagnóstico en DIAGEN es *Observaciones* y el de salida es *Diagnóstico* (véase la figura 3.3). (El nombre de los papeles del dominio coincide en este caso con el de las entidades correspondientes.) Puesto que inicialmente el sistema no dispone de las observaciones necesarias para obtener un diagnóstico definitivo, se deben solicitar nuevas pruebas que proporcionen nuevas observaciones.

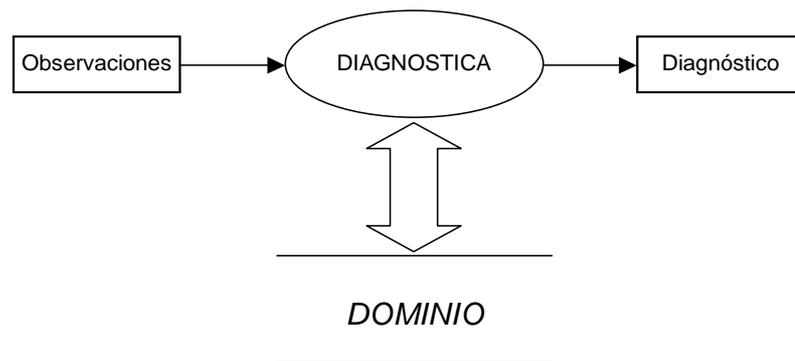


Figura 3.3: Papeles del dominio de la tarea DIAGNOSTICA, que todavía no ha sido descompuesta en subtareas.

En la anamnesis el médico comienza a generar hipótesis acerca del estado del paciente, que seguidamente comprueba. En el proceso de comprobación, rechazará ciertas hipótesis, las confirmará o generará otras nuevas. Este modo de actuar se repite durante la exploración física y la exploración complementaria.

Según el Método DIAGEN, la tarea de diagnóstico consiste en una iteración (REFINA DIAGNÓSTICO) de un proceso secuencial (SUGIERE HIPÓTESIS DIAGNÓSTICA seguido de CONFIRMA HIPÓTESIS DIAGNÓSTICA), de la que se sabe cuando se alcanza un diagnóstico válido que permite establecer una terapia. La descomposición de DIAGNOSTICA en subtareas aparece en la figura 3.4.

En cada paso de la iteración sugerencia-confirmación de hipótesis diagnósticas, el médico solicita nuevas pruebas hasta que se llega a un diagnóstico que permita asignar un tratamiento al paciente. Tal como se muestra en la figura 3.5, una serie de observaciones sugieren un conjunto de hipótesis. Una hipótesis se confirma con nuevas observaciones generadas a partir de la realización de las pruebas pertinentes y se convierte en un diagnóstico.

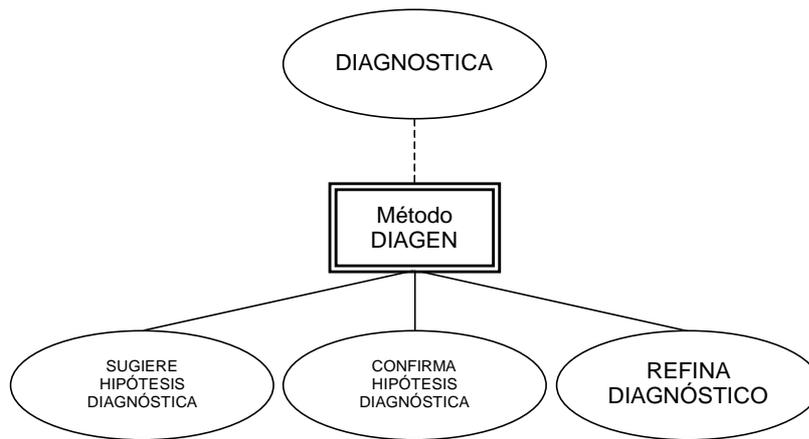


Figura 3.4: Descomposición de la tarea DIAGNOSTICA según el Método DIAGEN.

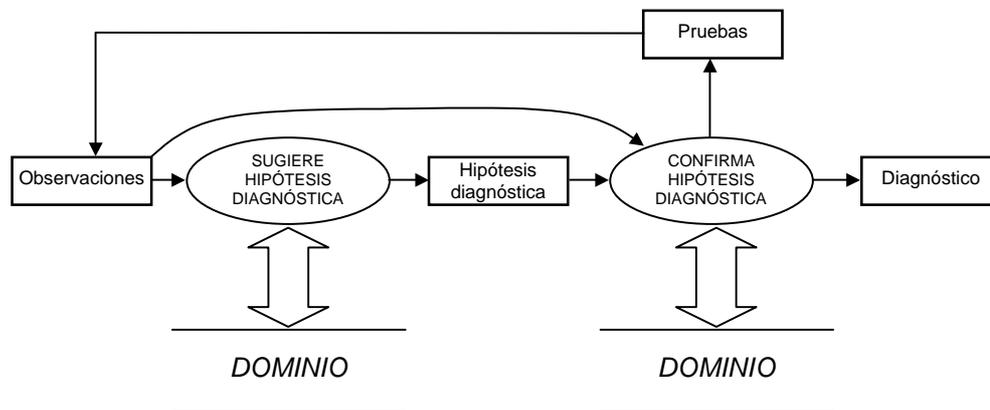


Figura 3.5: Papeles del dominio en la primera descomposición de tareas.

Existen diferentes opciones en DIAGEN para llevar a cabo la tarea SUGIERE HIPÓTESIS DIAGNÓSTICA: métodos heurísticos, métodos neuronales y métodos bayesianos. En general, cada médico puede seleccionar, para una determinada sub-tarea, cualquiera de los métodos disponibles para resolverla.

Un doble reto para la inteligencia artificial aplicada en medicina es la identificación de métodos de resolución de problemas que resulten adecuados para dominios médicos, así como su descripción en el nivel del conocimiento. Además, conviene disponer de criterios que identifiquen el método más adecuado para resolver cualquier tarea médica prefijada, del mismo modo que un ingeniero electrónico elige de forma precisa los componentes para construir un circuito con unas determinadas funciones.

## 3.3. Aplicación en oncología radioterápica

### 3.3.1. Descripción del problema

Tras las primeras entrevistas mantenidas con oncólogos pertenecientes al Servicio de Oncología Radioterápica del Hospital Clínico Universitario San Carlos de Madrid, quedó claro que entre los diversos factores que hay que tener en cuenta antes del establecimiento de un protocolo de tratamiento destaca la determinación de la extensión cancerígena lo más precisa y exactamente posible.

Averiguar cuál es la extensión de un cáncer requiere conocer cuáles son los mecanismos causales que rigen su expansión en el cuerpo del paciente. La **causalidad** es una característica propia de cualquier enfermedad cancerígena. El proceso de expansión de un cáncer se puede considerar como una secuencia de eventos causalmente interrelacionados. Esta última frase cobrará mayor sentido a medida que vayamos avanzando en la descripción de nuestro modelo sobre la evolución de un cáncer. El evento inicial en el proceso de desarrollo cancerígeno es la aparición de un tumor primario, los eventos intermedios consisten en la progresiva expansión del cáncer a nuevas localizaciones y los eventos finales están relacionados con la aparición de una serie de síntomas típicos, diferentes para cada tipo de cáncer concreto.

Los procesos causales que dirigen el crecimiento de un cáncer no tienen un carácter determinista. En general, se puede afirmar que existen varias fuentes de **incertidumbre** en este dominio médico. En primer lugar, tal como ya ha quedado apuntado, cualquier enfermedad cancerígena posee una naturaleza profundamente no determinista. En segundo lugar, la información que los oncólogos obtienen a partir de la anamnesis o de la realización de diferentes pruebas, puede ser imprecisa, incompleta o errónea.

El **tiempo** constituye una variable fundamental en la evolución de cualquier cáncer. Obviamente, la relación causal directa entre un par de eventos relacionados con la expansión de un cáncer no suele ser instantánea, ni tampoco de duración idéntica para todos los pacientes.

Hemos aplicado la metodología desarrollada dentro del proyecto DIAGEN al dominio de cáncer de nasofaringe. La nasofaringe es una cavidad de forma cuboidal situada en la parte alta de la faringe. Recibe el aire que inspiramos a través de

las fosas nasales y está rodeada, a *grosso modo*, por el velo del paladar, los oídos y la base de cráneo. Los tumores malignos que crecen en volumen dentro de la cavidad nasofaríngea se denominan *tumores vegetantes* y aquéllos que se desarrollan infiltrando los tejidos de la nasofaringe, o partes adyacentes a la misma, reciben el nombre de *tumores infiltrantes*.

### 3.3.2. Entidades del dominio

En nuestro dominio, todas las entidades existentes (síntomas, síndromes, etc.) poseen una propiedad común que hemos denominado *distribución* (véase la figura 3.6). Esta propiedad se introduce para poder representar la incertidumbre temporal asociada a cualquier evento relacionado con el avance de un cáncer de nasofaringe. De acuerdo con los expertos, hemos decidido utilizar una representación discreta del tiempo con el trimestre como unidad temporal. El rango temporal cubierto es de tres años; por tanto, la propiedad *distribución* admite un vector de trece valores. El rango temporal de tres años es considerado por los oncólogos como suficiente para estudiar la evolución de cualquier caso de cáncer de nasofaringe en el que la terapia no ha sido aún aplicada. Cualquiera de los doce primeros valores representa la probabilidad de aparición, en un trimestre dado, de la anomalía representada por la entidad. El último valor es la probabilidad de que dicha anomalía no ocurra en el período total de tiempo considerado. En definitiva, la propiedad *distribución* es un vector de trece valores comprendidos entre cero y uno, que están indexados por el tiempo.

Cada entidad creada representa un evento concreto que puede ocurrir una sola vez a lo largo del tiempo. De este modo, cualquier enfermedad formada por un conjunto de procesos irreversibles tendría una representación inmediata en nuestro modelo. Ése es el caso del dominio que nos ocupa, donde nos interesa modelar la progresión irreversible de un cáncer antes de aplicar la terapia. En consecuencia, en la propiedad *distribución* la suma de los trece valores de probabilidad debe ser igual a la unidad, debido a que dichos valores son exclusivos y exhaustivos. Son exclusivos porque dos de ellos no pueden ser ciertos a la vez y son exhaustivos porque no existe otro valor diferente a los mismos que pueda llegar a ser cierto.

En el proceso de construcción del sistema, cuya base teórica queda descrita en

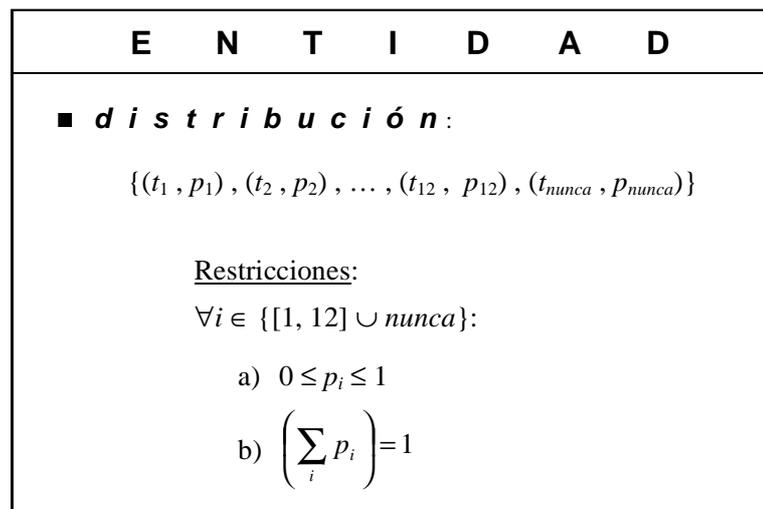


Figura 3.6: Estructura general de una entidad cualquiera del dominio.

el capítulo 5 y cuyos detalles prácticos aparecen en el capítulo 7, hemos definido más de un centenar de entidades. Cada una de ellas se denomina “Aparición de  $X$ ”, donde  $X$  hace referencia a una anomalía relacionada con la enfermedad. Por tanto, cada entidad representa un evento que se corresponde con la aparición de una determinada anomalía.

A continuación figuran algunos ejemplos de entidades del dominio. Hemos omitido las palabras “Aparición de” en el nombre de cada entidad.

## HALLAZGOS

Ganglios cervicales afectados  $\left\{ \begin{array}{l} \text{en lado derecho} \\ \text{en lado izquierdo} \end{array} \right.$

Ganglios supraclaviculares afectados  $\left\{ \begin{array}{l} \text{en lado derecho} \\ \text{en lado izquierdo} \end{array} \right.$

Metástasis  $\left\{ \begin{array}{l} \text{cerebral} \\ \text{hepática} \\ \text{ósea} \\ \text{pulmonar} \end{array} \right.$

Tumor infiltrante primario	{	en cara anterior nasofaríngea en cara lateral derecha nasofaríngea en cara lateral izquierda nasofaríngea en cara posterior nasofaríngea en cara superior nasofaríngea
Tumor infiltrante extendido	{	a cara anterior nasofaríngea a cara lateral derecha nasofaríngea a cara lateral izquierda nasofaríngea a cara posterior nasofaríngea a cara superior nasofaríngea
Tumor infiltrante extendido	{	a espacio parotídeo derecho a espacio parotídeo izquierdo
Tumor infiltrante extendido	a	espacio retrofaríngeo
Tumor infiltrante extendido	{	a fosa nasal derecha a fosa nasal izquierda
Tumor infiltrante extendido	{	a oído interno derecho a oído interno izquierdo a oído medio derecho a oído medio izquierdo
Tumor infiltrante extendido	{	a parte anterior derecha de base de cráneo a parte anterior izquierda de base de cráneo a parte media derecha de base de cráneo a parte media izquierda de base de cráneo a parte posterior derecha de base de cráneo a parte posterior izquierda de base de cráneo
Tumor infiltrante extendido	{	a seno cavernoso derecho a seno cavernoso izquierdo
Tumor infiltrante extendido	{	a seno maxilar derecho a seno maxilar izquierdo
Tumor infiltrante extendido	{	a velo del paladar y amígdala derechos a velo del paladar y amígdala izquierdos

Tumor vegetante primario {  
 en cara anterior nasofaríngea  
 en cara lateral derecha nasofaríngea  
 en cara lateral izquierda nasofaríngea  
 en cara posterior nasofaríngea  
 en cara superior nasofaríngea

## SIGNOS

Hemorragia {  
 en cara anterior nasofaríngea  
 en cara lateral derecha nasofaríngea  
 en cara lateral izquierda nasofaríngea  
 en cara posterior nasofaríngea  
 en cara superior nasofaríngea

Infección {  
 en aparato auditivo derecho  
 en aparato auditivo izquierdo

Infección en nasofaringe

Infección {  
 en seno maxilar derecho  
 en seno maxilar izquierdo

Parálisis {  
 del velo del paladar hacia la derecha  
 del velo del paladar hacia la izquierda

## SÍNTOMAS

Acúfenos {  
 en lado derecho  
 en lado izquierdo

Anosmia

Autofonía

Cefalea

Deglución dificultosa

Desviación de la lengua {  
 hacia lado derecho  
 hacia lado izquierdo

Disfonía

Edema  $\left\{ \begin{array}{l} \text{en brazo derecho} \\ \text{en brazo izquierdo} \end{array} \right.$

Edema en esclavina

Elevación  $\left\{ \begin{array}{l} \text{de hombro derecho} \\ \text{de hombro izquierdo} \end{array} \right.$

Espujo hemorrágico

Espujo purulento

Fiebre

Hemorragia nasal

Hipoacusia  $\left\{ \begin{array}{l} \text{en lado derecho} \\ \text{en lado izquierdo} \end{array} \right.$

Irritación posnasal

Obstrucción nasal persistente  $\left\{ \begin{array}{l} \text{en lado derecho} \\ \text{en lado izquierdo} \end{array} \right.$

Otalgia  $\left\{ \begin{array}{l} \text{en lado derecho} \\ \text{en lado izquierdo} \end{array} \right.$

Otorragia  $\left\{ \begin{array}{l} \text{en lado derecho} \\ \text{en lado izquierdo} \end{array} \right.$

Otorrea  $\left\{ \begin{array}{l} \text{en lado derecho} \\ \text{en lado izquierdo} \end{array} \right.$

Rinolalia

Rinorrea

Sensación de plenitud en oído  $\left\{ \begin{array}{l} \text{derecho} \\ \text{izquierdo} \end{array} \right.$

Trismus

Vértigo

## SÍNDROMES

Síndrome del agujero rasgado posterior  $\left\{ \begin{array}{l} \text{en lado derecho} \\ \text{en lado izquierdo} \end{array} \right.$

Síndrome cóndilo rasgado posterior  $\left\{ \begin{array}{l} \text{en lado derecho} \\ \text{en lado izquierdo} \end{array} \right.$

Síndrome de Gradenigo  $\left\{ \begin{array}{l} \text{en lado derecho} \\ \text{en lado izquierdo} \end{array} \right.$

Síndrome de la hendidura esfenoidal  $\left\{ \begin{array}{l} \text{en lado derecho} \\ \text{en lado izquierdo} \end{array} \right.$

Síndrome petrosoesfenoidal  $\left\{ \begin{array}{l} \text{en lado derecho} \\ \text{en lado izquierdo} \end{array} \right.$

Síndrome del seno cavernoso  $\left\{ \begin{array}{l} \text{en lado derecho} \\ \text{en lado izquierdo} \end{array} \right.$

Síndrome del vértice de la órbita  $\left\{ \begin{array}{l} \text{en lado derecho} \\ \text{en lado izquierdo} \end{array} \right.$

### 3.3.3. Relaciones presentes en el dominio

Únicamente definimos un tipo de relación en nuestro modelo a la que denominamos “produce”, ya que representa una relación de causalidad entre dos entidades cualesquiera del dominio. Esta relación incorpora además aspectos temporales y de incertumbre propios de los mecanismos causales presentes en una enfermedad cancerígena.

La definición de una relación particular entre dos entidades del dominio requiere la especificación de los siguientes datos (véase la figura 3.7):

- **Causa:** es la entidad que ejerce como causa en la relación.
- **Efecto:** es la entidad que representa el efecto dentro de la relación.
- **Distribución condicional:** es un vector de trece valores comprendidos entre cero y uno, que están indexados por el tiempo transcurrido entre la ocurrencia de la *Causa* y la ocurrencia del *Efecto*. En concreto, la *Distribución condicional* de una relación está formada por:

$$dc \equiv \{(1, p_1), (2, p_2), \dots, (12, p_{12}), (nunca, p_{nunca})\}$$

donde  $p_i$  ( $1 \leq i \leq 12$ ) es la probabilidad de que el *Efecto* ocurra en el trimestre  $i$  después de la ocurrencia de la *Causa*, suponiendo que el resto de causas del *Efecto* están ausentes. Si  $i = nunca$ ,  $p_i$  es la probabilidad de que el *Efecto* no ocurra, suponiendo que *Causa* es la única causa presente del *Efecto*.

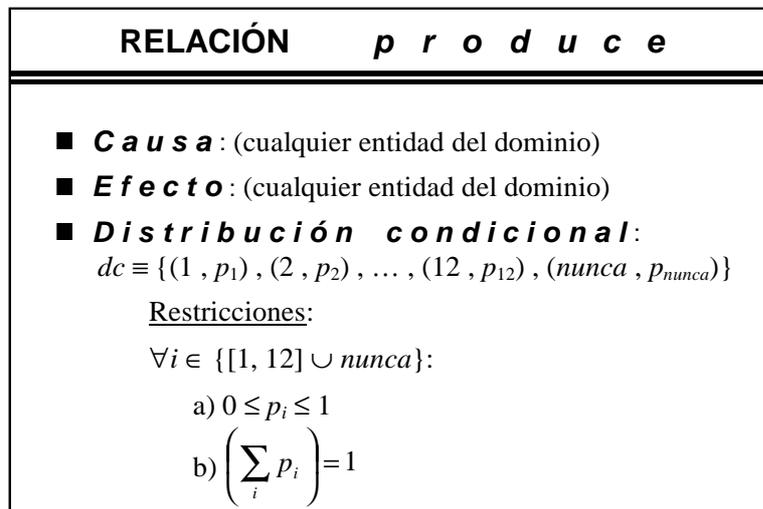


Figura 3.7: Estructura general de una relación del dominio.

A continuación figuran algunos ejemplos de las cerca de trescientas relaciones que hemos definido para el dominio de cáncer de nasofaringe:

Tumor vegetante primario en cara anterior  $\longrightarrow$  Tumor vegetante ocupando fosa nasal derecha

Tumor infiltrante primario en cara superior  $\longrightarrow$  Tumor infiltrante extendido a cara lateral izquierda

Tumor infiltrante primario en cara posterior  $\longrightarrow$  Ganglios cervicales afectados en lado derecho

Tumor vegetante primario en cara anterior  $\longrightarrow$  Metástasis pulmonar

Tumor infiltrante extendido a seno cavernoso derecho  $\longrightarrow$  Síndrome del seno cavernoso en lado derecho

Tumor vegetante ocupando fosa nasal derecha  $\longrightarrow$  Anosmia

Hemorragia en cara posterior  $\longrightarrow$  Esputo hemorrágico

Tumor vegetante primario en cara superior  $\longrightarrow$  Infección en nasofaringe

Infección en nasofaringe  $\longrightarrow$  Cefalea

### 3.3.4. Descomposición de tareas

Teniendo en cuenta la descomposición jerárquica de tareas diseñada en el proyecto DIAGEN para la tarea general de diagnóstico, la parte esencial del diagnóstico de extensión de un cáncer de nasofaringe reside en la subtarea *Sugiere hipótesis diagnóstica*, que genera una hipótesis diagnóstica a partir de una serie de observaciones. Esto es así como consecuencia de que la subtarea *Confirma hipótesis diagnóstica* tiene carácter sistemático en nuestro dominio: tras la exploración visual inicial de la nasofaringe (rinoendoscopia), se procede a realizar una biopsia en caso de identificar un tumor o una zona mucosa sospechosa y, finalmente, se lleva a cabo un estudio de extensión de carácter radiológico.

Decidimos basar la realización de la subtarea *Sugiere hipótesis diagnóstica* en el empleo del formalismo de redes bayesianas, que aparecen tratadas en el capítulo 4. Debido a la importancia de utilizar una representación explícita del tiempo en nuestro dominio, se hizo necesario el uso de redes bayesianas que permitieran llevar a cabo razonamiento temporal. De entre los diferentes tipos de redes bayesianas para razonamiento temporal existentes, ninguno de ellos satisfacía completamente los requisitos que se planteaban en el dominio de cáncer de nasofaringe. Debido a ello, nos vimos en la necesidad de desarrollar un nuevo método para razonamiento temporal con redes bayesianas, al que denominamos *redes de eventos probabilistas en tiempo discreto*. La principal aportación de este tipo de redes, tal como se indica en el capítulo 5, es la definición de nuevos modelos temporales de interacción entre un efecto y sus causas. Estos modelos reciben el nombre de *puertas probabilistas temporales*.

La tarea *Sugiere hipótesis diagnóstica*, tal como se indica en la figura 3.8, se descompone en tres subtareas: *Recoge evidencia*, *Propaga evidencia* y *Genera hipótesis diagnóstica*.

En líneas generales, en la subtarea *Recoge evidencia* el oncólogo transforma en hallazgos la información que le proporciona el paciente, sus propias observaciones

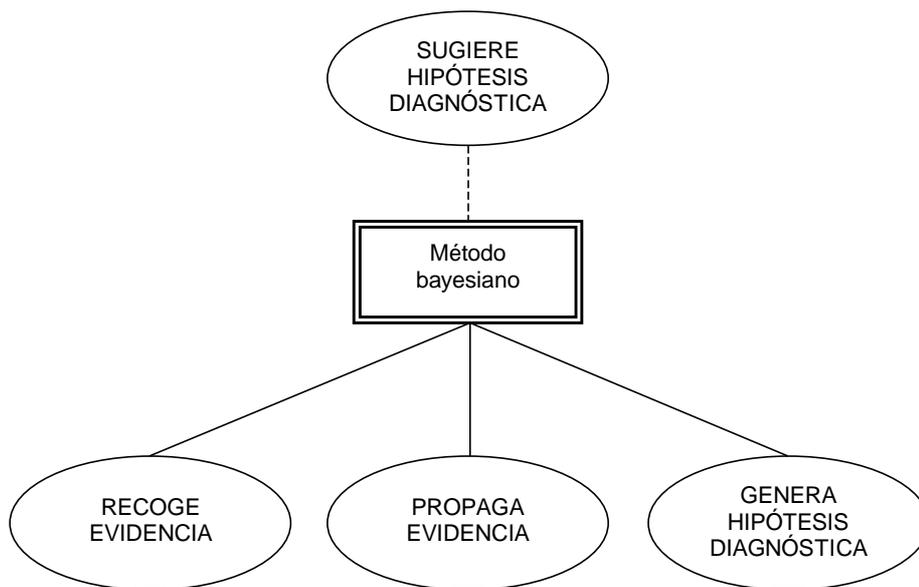


Figura 3.8: Descomposición de la tarea *Sugiere hipótesis diagnóstica* mediante el método bayesiano.

y los resultados de las pruebas. Cada hallazgo lleva asociada información temporal sin la cual no sería posible llegar a un diagnóstico fiable. Es decir, conjuntos idénticos de hallazgos, pero obtenidos en tiempos distintos, pueden producir diagnósticos diferentes.

La subtarea *Propaga evidencia* se encarga de registrar el impacto de los hallazgos sobre el resto de entidades del dominio. Al final del proceso de propagación de la evidencia, los eventos representados por una parte de las entidades del dominio se harán más probables.

La subtarea *Genera hipótesis diagnóstica* permite elaborar una hipótesis diagnóstica a partir de los eventos más probables generados en la subtarea anterior.

### 3.3.5. Diagrama inferencial

La entrada de la tarea *Recoge evidencia* está formada por un conjunto de observaciones, tal como se indica en la figura 3.9. La salida de dicha tarea viene representada por el papel del dominio denominado *Hallazgos temporales*. Puede hacer el papel de hallazgo temporal cualquier hallazgo, signo, síntoma o síndrome de los definidos

en secciones previas. La característica distintiva de una entidad que haga el papel de hallazgo temporal reside en su distribución de probabilidad. Dado un hallazgo temporal con

$$\text{distribución} \equiv \{(t_1, p_1), (t_2, p_2), \dots, (t_{12}, p_{12}), (t_{nunca}, p_{nunca})\},$$

se debe verificar que  $\exists t_{ocurrencia} \in \{[1, 12] \cup nunca\}$  tal que

$$\begin{cases} p_i = 1 & \text{si } t_i = t_{ocurrencia} \\ p_i = 0 & \text{en caso contrario} \end{cases}$$

Es decir, existe certeza sobre la ocurrencia del hallazgo en un determinado tiempo.

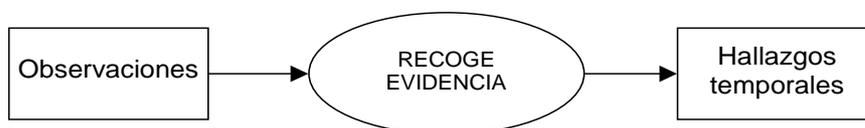


Figura 3.9: Subtarea *Recoge evidencia*.

Cualquier hallazgo temporal resultante de la tarea *Recoge evidencia* sirve de entrada a la tarea *Propaga evidencia*. Teniendo en cuenta los hallazgos temporales existentes y la información causal sobre la enfermedad proporcionada por los oncólogos, la tarea *Propaga evidencia* se encarga de obtener una distribución de probabilidades a posteriori (véase la figura 3.10) para cada una de las entidades del dominio que no actúe como hallazgo temporal. Cada distribución a posteriori recoge la influencia de la evidencia, o hallazgos temporales disponibles en relación a un paciente, sobre la creencia en la ocurrencia a lo largo del tiempo de un evento concreto relacionado con la enfermedad. Dicha creencia, en forma de probabilidades, puede hacer referencia tanto al pasado como al futuro. En el primer caso estaríamos hablando de **diagnóstico** de la enfermedad, es decir, nos ocuparíamos de cuál ha sido la secuencia temporal de eventos desde la aparición del tumor primario hasta el desarrollo presente del cáncer en el paciente. En el segundo caso nos ocuparíamos del **pronóstico** de la enfermedad, que consiste en establecer qué evolución seguiría el cáncer en el paciente a partir del momento actual si no se aplicara ningún tratamiento.

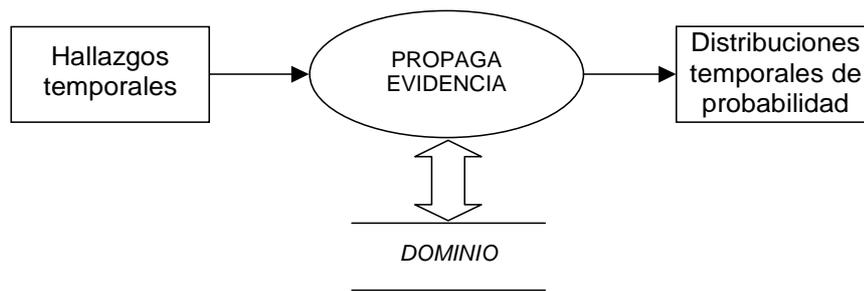


Figura 3.10: Subtarea *Propaga evidencia*.

La tarea *Genera hipótesis diagnóstica* parte de unas determinadas distribuciones de probabilidad a posteriori para todos los eventos asociados con la progresión de un cáncer y permite discriminar aquellos eventos de mayor probabilidad. Del grafo formado por todas las entidades y relaciones de causalidad del dominio, sólo una parte del mismo adquiere ahora relevancia. En dicho subgrafo han aumentado las probabilidades de ocurrencia de los eventos contenidos en el mismo, como consecuencia de la aparición de ciertos hallazgos temporales a partir de la tarea *Recoge evidencia* y de la propagación de la influencia de dichos hallazgos a partir de la tarea *Propaga evidencia*. El subgrafo de eventos relevantes constituye toda una hipótesis diagnóstica, que sirve de salida a la tarea *Genera hipótesis diagnóstica*, tal como se indica en la figura 3.11.

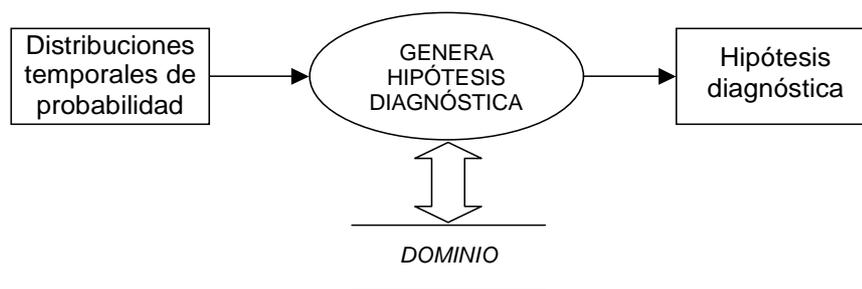


Figura 3.11: Subtarea *Genera hipótesis diagnóstica*.

### 3.3.6. Control de las inferencias y conexión con el dominio

La tarea *Sugiere hipótesis diagnóstica* se lleva a cabo a partir del desarrollo secuencial de las tres subtareas de las que se compone: *Recoge evidencia*, *Propaga evidencia* y *Sugiere hipótesis diagnóstica*.

Las observaciones que la tarea *Recoge evidencia* transforma en hallazgos temporales, no son más que determinaciones cuantitativas o cualitativas de una magnitud, o de la presencia o ausencia de algo en el paciente. Tras un simple proceso de abstracción, el oncólogo identifica el hallazgo que se deriva de una observación realizada. Cada hallazgo, por otra parte, tiene su representación correspondiente como entidad del dominio.

Previamente ya hemos reseñado la importancia que tiene para el diagnóstico de la extensión de un cáncer, el conocimiento del tiempo en que se producen los diferentes eventos asociados al desarrollo de la enfermedad. Si a esto unimos el hecho de que los mecanismos causales de un cáncer tienen una naturaleza de carácter incierto, el método de representación de conocimiento que mejor se adapta a tales características es el de una **red bayesiana** que permita una **representación explícita del tiempo**. Las redes bayesianas ofrecen la ventaja de estar basadas en una teoría matemática formal: la teoría de la probabilidad. Concretando aún más, el método que hemos utilizado para representar el conocimiento de los oncólogos en relación a un cáncer de nasofaringe es una **red de eventos probabilistas en tiempo discreto**. La definición y formalización de este tipo de red bayesiana para razonamiento temporal es original de la presente tesis doctoral y, aunque en un principio fue concebida para modelar los procesos de crecimiento de un cáncer, tiene una aplicabilidad mucho más general y se puede aplicar a otros dominios muy diferentes. Una red de eventos probabilistas en tiempo discreto constituye un método apropiado para el modelado de procesos causales sujetos a incertidumbre y caracterizados por la ocurrencia de una serie de eventos a lo largo del tiempo.

Cada una de las entidades definidas para el caso de cáncer de nasofaringe pasa a ser un nodo de la red de eventos probabilistas en tiempo discreto. A su vez, cada una de las relaciones de causalidad establecidas entre dos entidades del dominio se representa en la red de eventos por medio de un arco dirigido que une dos nodos. Dentro del método de redes de eventos probabilistas en tiempo discreto, hemos

desarrollado nuevos modelos de interacción causal denominados *puertas probabilistas temporales*. En concreto, en el dominio de cáncer de nasofaringe hemos hecho amplio uso del modelo de **puerta O probabilista temporal**. La definición formal de las puertas probabilistas temporales aparece en el capítulo 5.

Para completar la tarea *Propaga evidencia*, cada hallazgo temporal se introduce en la red asignando al nodo correspondiente el valor temporal determinado por el período de ocurrencia del hallazgo. La propagación de la evidencia se realiza por medio de algoritmos generales para el cálculo de probabilidades a posteriori en redes bayesianas. Tras la propagación de la evidencia, se obtiene una serie de distribuciones de probabilidad a posteriori para el conjunto de nodos de la red que no hacen el papel de hallazgo temporal. Cabe reseñar que en aquellos casos en que no existiera ningún hallazgo, la propagación de la evidencia produciría siempre los mismos valores para la distribución de probabilidad en cada nodo. Estos valores son las probabilidades a priori.

La tarea *Genera hipótesis diagnóstica* se encarga de proponer una hipótesis diagnóstica a partir de las distribuciones de probabilidad a posteriori obtenidas tras la aplicación de la tarea *Propaga evidencia*. El modo de establecer una hipótesis diagnóstica consiste en fijar una probabilidad umbral  $p_0$ , en general tan próxima a cero como queramos. A continuación se seleccionan aquellos nodos o entidades del dominio para los que  $p_{nunca} < p_0$ . De esta forma obtenemos el subgrafo más relevante para un paciente particular con una serie de hallazgos concretos. Este subgrafo aporta, además, información temporal a partir de las distribuciones de probabilidad a posteriori para cada nodo. En cada distribución existirá un período temporal —un trimestre en nuestro caso— donde la probabilidad de ocurrencia del evento asociado al nodo sea máxima.

A modo de resumen, el subgrafo de nodos relevantes aporta una gran cantidad de información espacio-temporal y, si se nos permite la metáfora, es como una película donde ha quedado grabado el proceso de crecimiento cancerígeno. Dicho crecimiento empieza implicando a los nodos sin padre del subgrafo, asociados a la aparición de un tumor primario en la nasofaringe, y termina afectando a los nodos sin hijos, que hacen referencia a la aparición de distintos síntomas, síndromes... en el paciente.

En consecuencia, el diagnóstico de extensión de un cáncer de nasofaringe, lejos

---

de ser una simple clasificación de un conjunto de hallazgos mediante una etiqueta lingüística, es en realidad un modelo de los mecanismos causales que han dirigido la evolución de la enfermedad en el paciente. Dicho modelo, además de aportar información espacial (qué partes del cuerpo del paciente están afectadas por el cáncer), contribuye con información de carácter temporal (cuándo empezó a verse afectada cada parte). Por otra parte, siempre se puede recurrir a los diferentes métodos de explicación del razonamiento en redes bayesianas [78] para obtener una mejor comprensión de los resultados de la inferencia.



## Parte II

# RAZONAMIENTO TEMPORAL PROBABILISTA



# Capítulo 4

## Redes bayesianas y tiempo

### 4.1. Redes bayesianas

Las redes bayesianas [18, 98, 106] constituyen un método para la representación de conocimiento incierto, que permite establecer razonamientos basados en la teoría de la probabilidad.

Cada nodo de una red bayesiana está asociado a una variable aleatoria, que puede tomar valores dentro de un rango discreto o continuo. Dichos valores son exclusivos y exhaustivos para cada variable de la red. En la presente memoria de tesis doctoral suponemos que todas las variables consideradas son discretas. En general, los enlaces de la red definen relaciones de dependencia probabilística entre variables, si bien en determinados dominios de aplicación la conexión entre dos nodos tiene un significado causal.

Formalmente, una red bayesiana es un grafo dirigido acíclico más una distribución de probabilidad sobre sus variables, que satisface la condición de Markov: la probabilidad de cualquier variable  $V$ , una vez que han sido determinados los valores de todos sus padres, es independiente de las variables que no son descendientes de  $V$  en la red. Como consecuencia de la condición anterior, la probabilidad conjunta de una distribución de valores sobre la totalidad de variables aleatorias de una red bayesiana puede ser expresada del siguiente modo:

$$P(x_1, \dots, x_n) = \prod_i P(x_i \mid pa(x_i)) \quad (4.1)$$

donde  $pa(x_i)$  representa una configuración de valores para el conjunto de padres de la variable  $X_i$ . Es decir, la probabilidad conjunta factoriza de acuerdo a la topología de la red, como consecuencia de las relaciones de independencia condicional codificadas en la misma. Este resultado es la base de los algoritmos desarrollados para el cómputo de las probabilidades a posteriori en redes bayesianas.

El diseño de una red bayesiana comienza con la definición de su grafo. A continuación es necesario establecer las probabilidades condicionales de cada nodo dados los valores de sus padres. Para cada nodo sin padres, únicamente hay que definir sus probabilidades a priori. La inferencia consiste en fijar los valores de las variables observadas y calcular la probabilidad a posteriori de las variables no observadas.

En el caso general, es necesario asignar a cada nodo un conjunto de probabilidades condicionales que crece exponencialmente con el número de padres del nodo. Este hecho dificulta el proceso de adquisición de los parámetros de la red, su almacenamiento y la propagación de la evidencia. Los inconvenientes citados motivaron la aparición de nuevos modelos de interacción causal denominados *modelos canónicos* [48, 106], que permiten simplificar tanto la construcción de la red como el cómputo de las probabilidades a posteriori. El ejemplo más conocido de modelo canónico es la puerta O probabilista, que requiere únicamente un parámetro independiente por cada padre.

#### 4.1.1. Métodos generales de inferencia en redes bayesianas

La inferencia probabilística en una red bayesiana consiste en el cálculo de las probabilidades a posteriori de las variables no observadas, dados los valores que toman ciertas variables observadas de la red.

A partir de las leyes de la teoría de la probabilidad, cualquier probabilidad condicionada o marginal se puede obtener a partir de la probabilidad conjunta. La probabilidad conjunta de las variables de una red bayesiana es el producto de todas las probabilidades condicionales incluidas en la red. Desafortunadamente, aunque este método para el cálculo de las probabilidades a posteriori de las variables parece el más inmediato, su complejidad crece exponencialmente con el número de nodos de la red.

### Métodos de eliminación de variables y métodos de agrupamiento

Una forma de evitar la complejidad propia del método mencionado en el párrafo anterior consiste en sumar primero sobre ciertas variables antes de multiplicar todos los potenciales. (Cada tabla de probabilidad es un potencial y el resultado de multiplicar dos potenciales es un nuevo potencial [81].) Por ejemplo, a partir de la red de la figura 4.1, la probabilidad a posteriori de  $A$  dada la evidencia  $\{H = h_k\}$ ,  $P(a | h_k)$ , se puede calcular del siguiente modo:

$$P(a | h_k) = \frac{P(a, h_k)}{P(h_k)} = \frac{P(a, h_k)}{\sum_a P(a, h_k)}$$

con

$$\begin{aligned} P(a, h_k) &= \sum_b \sum_d \sum_f \sum_g P(a, b, d, f, g, h_k) \\ &= \sum_b \sum_d \sum_f \sum_g P(a) \cdot P(b | a) \cdot P(d | a) \cdot P(f) \cdot P(g | b, d, f) \cdot P(h_k | g) \quad (4.2) \end{aligned}$$

$$= P(a) \cdot \sum_b P(b | a) \cdot \sum_d P(d | a) \cdot \sum_f P(f) \cdot \sum_g P(g | b, d, f) \cdot P(h_k | g) \quad (4.3)$$

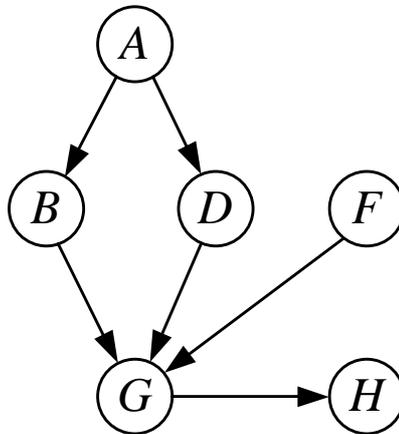


Figura 4.1: Ejemplo de red bayesiana.

Nótese que la ecuación 4.3 supone un cálculo más eficiente que la ecuación 4.2. Este proceso de ordenamiento de los potenciales y las sumas sobre dichos potenciales es el fundamento de los algoritmos de eliminación de variables (consúltese, por ejemplo, [36, 42]).

En redes con bucles, la principal dificultad de este algoritmo consiste en encontrar el orden de eliminación óptimo, el cual es de crucial importancia para la eficiencia del cálculo de la probabilidad [85].

El fundamento de los algoritmos de agrupamiento es esencialmente el mismo. Uno de los pasos en este tipo de algoritmos es la construcción de un *árbol de unión* con las siguientes propiedades:

- Un árbol de unión asociado a una red bayesiana es un árbol no dirigido tal que cada nodo del mismo representa un cúmulo (*cluster*), es decir, un subconjunto de las variables de la red.
- Para cada familia de la red existe al menos un cúmulo que contiene las variables de la familia.
- Si una variable aparece en dos cúmulos  $C_i$  y  $C_j$  entonces debe aparecer en todos los cúmulos del árbol que se encuentren en el camino que une  $C_i$  y  $C_j$ .

El modo general de construir un árbol de unión consiste en moralizar el grafo de la red bayesiana (enlazando los padres de cada nodo entre sí) y triangular el grafo no dirigido asociado resultante; cada clique<sup>1</sup> del árbol moralizado y posteriormente triangulado se convierte en un cúmulo del árbol de unión, que en este caso se llama *árbol de cliques*. Después de asignar cada tabla de probabilidades condicionales (TPC) de la red a un cúmulo e introducir la evidencia, el cálculo de las probabilidades a posteriori se realiza mediante el intercambio de mensajes entre cúmulos vecinos [70, 81, 123].

Esencialmente, cada árbol de unión realiza las mismas operaciones que el algoritmo de eliminación de variables con un orden determinado de eliminación. El árbol de unión representa una estructura que permite almacenar y combinar los potenciales, además de gestionar los resultados intermedios. Por esta razón, la eliminación de variables es más eficiente para consultas referentes a un solo nodo, mientras que los algoritmos de agrupamiento lo son cuando queremos calcular las probabilidades a posteriori de todas y cada una de las variables.

---

<sup>1</sup>Un clique es un conjunto de nodos completamente conexo maximal, es decir, un conjunto de nodos tal que cualquiera de ellos está conectado con todos los demás y no hay ningún otro clique que lo incluya.

## Métodos de condicionamiento

Existen algoritmos para la propagación de la evidencia en redes bayesianas simplemente conexas (aquéllas en las que entre dos cualesquiera de sus nodos hay exactamente un camino), que están basados en el paso de mensajes probabilísticos  $\pi$  y  $\lambda$  entre nodos vecinos. En concreto, Pearl [102] propuso un algoritmo de este tipo para redes con estructura de árbol. Posteriormente, Kim [73] generalizó dicho algoritmo para poliárboles (grafos dirigidos simplemente conexos). Estos algoritmos poseen una complejidad proporcional al número de nodos y se prestan a una implementación distribuida.

Los métodos que acabamos de mencionar, basados en el paso de mensajes, no permiten tratar redes con bucles, por lo que en la práctica no resultan de gran utilidad. Los algoritmos de condicionamiento surgieron ante la necesidad de desarrollar métodos que pudieran tratar los bucles y que admitieran una implementación distribuida.

La primera versión de un algoritmo de condicionamiento fue propuesta por Pearl [103, 104] y está basado en el concepto de independencia condicional. Cuando hay un solo bucle, el método consiste en condicionar sobre los valores de una variable del bucle correspondiente a cualquier nodo con hijos en el bucle, realizando la propagación de la evidencia para cada valor de dicha variable, del mismo modo que si la red fuera un poliárbol. Finalmente, se han de ponderar las probabilidades obtenidas para cada valor. En el caso de la existencia de más de un bucle, sería necesario condicionar sobre varias variables, que formarían el llamado “conjunto de corte”.

El algoritmo original de Pearl, conocido como *condicionamiento global*, fue modificado por Peot y Shachter [107], que diseñaron un método de *condicionamiento por bloques*. Un bloque es una parte de la red tal que entre dos nodos cualesquiera hay al menos dos caminos que no comparten ningún arco común. En este método la propagación de mensajes entre bloques es análoga a la propagación entre los nodos de un poliárbol. Sin embargo, dentro de cada bloque la propagación coincide con la del condicionamiento global, por lo que el método se vuelve ineficiente si los bloques son grandes.

Más tarde, Díez [46] creó un método de *condicionamiento local* basado en condicionar sólo dentro de cada bucle. De este modo se reduce drásticamente la com-

plejidad del algoritmo de condicionamiento global, la cual varía exponencialmente con el número de nodos del conjunto de corte.

### Métodos de simulación estocástica

Algunos de los métodos exactos que hemos citado sólo permiten realizar inferencia en redes con estructura de árbol o poliárbol. A su vez, aquellos métodos exactos que sí permitían tratar con redes de estructura general, resultan cada vez más ineficientes a medida que aumenta el número de nodos de la red o la complejidad estructural de la misma.

Existen métodos aproximados para la propagación de la evidencia, aplicables a cualquier estructura de red. Estos métodos obtienen las probabilidades a posteriori de cada variable de forma aproximada. Básicamente, generan muestras de tamaño  $N$  (número de nodos o variables de la red) a partir de las cuales se aproximan los valores de probabilidad buscados, teniendo en cuenta la frecuencia de aparición de cada valor en la muestra y el tamaño de la misma. Este esquema básico se puede ampliar asignando un peso —o probabilidad— a cada muestra. Al final del proceso de simulación, los pesos son normalizados y utilizados en la estimación de las probabilidades a posteriori.

En general, en lo que resta de sección supondremos la existencia de un conjunto de variables  $X = \{X_1, \dots, X_N\}$  con función de probabilidad conjunta  $P(\mathbf{x})$  y un subconjunto  $E$  de variables de  $X$  que toma valores conocidos. Dada una función de probabilidad conjunta  $P(\mathbf{x})$  asociada a una red bayesiana, cada método aproximado particular define un modo específico de generar muestras y calcular sus pesos.

**Método de muestreo lógico.** El método de muestreo lógico [67] asigna valores secuencialmente a todas las variables, incluidas las observadas, muestreando primero los padres y luego los hijos. Por tanto, sólo se muestrea una variable cuando todos sus padres ya han sido simulados y tienen valores asignados. Cada variable  $X_i$  es simulada a partir de su TPC,  $P(x_i \mid pa(x_i))$ , donde  $pa(x_i)$  representa una configuración de valores para los padres de  $X_i$ .

En el momento en que el valor simulado para un nodo observado difiera del valor realmente observado, se rechaza la muestra. Rechazar una muestra sería equivalente

a asignarle un peso nulo. El caso contrario supone aceptar la muestra asignándole un peso unitario.

Cualquier probabilidad a posteriori o condicional que queramos obtener se puede aproximar hallando el cociente entre el número de casos no rechazados que satisfacen nuestra consulta y el número total de casos no rechazados.

Con más frecuencia de la deseada, el presente método puede conducir a un alto porcentaje de rechazos, lo cual implica aumentar el número de simulaciones necesario para obtener resultados fiables. Esto es así cuando la probabilidad a priori de la evidencia,  $P(e)$ , es pequeña.

El resto de los métodos aproximados revisados en esta sección intenta solucionar el problema de las muestras rechazadas que aparecen en el muestreo lógico.

**Método de muestreo uniforme.** En el método de muestreo uniforme [67], el valor de cada variable  $X_i$  se simula a partir de la distribución siguiente:

$$\begin{cases} \frac{1}{\text{n}^\circ \text{ de valores de } X_i} & \text{si } X_i \notin E \\ 1 & \text{si } X_i \in E \text{ y } x_i = e_i \\ 0 & \text{si } X_i \in E \text{ y } x_i \neq e_i \end{cases}$$

Por tanto, el valor asignado a las variables observadas siempre es el valor observado y por eso nunca habrá muestras rechazadas. En realidad, sólo se simulan las variables no observadas. Dada una muestra  $\mathbf{x} = (x_1, \dots, x_N)$ , se le asigna un peso dado por  $P(\mathbf{x})$ , que se calcula según la ecuación 4.1.

En este método, las variables no observadas pueden ser simuladas en cualquier orden. Cuando el conjunto de posibles muestras no esté distribuido uniformemente, existe el inconveniente de que se pueden llegar a generar muchas muestras poco representativas y, por tanto, los valores de probabilidad obtenidos pueden ser erróneos.

**Método de ponderación por verosimilitud.** El método de ponderación por verosimilitud [55, 121] intenta ofrecer una solución al problema de los pesos descompensados que se producía en el método de muestreo uniforme.

En este método se utiliza la siguiente distribución en la simulación de cada

variable  $X_i$ :

$$\begin{cases} P(x_i | pa(x_i)) & \text{si } X_i \notin E \\ 1 & \text{si } X_i \in E \text{ y } x_i = e_i \\ 0 & \text{si } X_i \in E \text{ y } x_i \neq e_i \end{cases}$$

El orden de simulación de las variables debe ser descendente, ya que los padres deben ser muestreados antes de hacer lo propio con su hijo. El peso asociado a una muestra  $\mathbf{x} = (x_1, \dots, x_N)$  es  $\prod_{X_i \in E} P(e_i | pa(x_i))$ . Si la probabilidad a priori de la evidencia no está muy próxima a cero, este método se comporta satisfactoriamente.

**Método de muestreo hacia atrás.** En el método de muestreo hacia atrás [56] no es necesario muestrear los padres antes que los hijos, ya que combina dos tipos de muestreo: uno hacia adelante y otro hacia atrás. En concreto, utiliza muestreo hacia adelante en los nodos cuyos descendientes no han sido observados. En cambio, se realiza muestreo hacia atrás —una vez asignado un valor al nodo— en nodos que tienen algún descendiente con evidencia.

En el muestreo que se realiza hacia atrás, únicamente se podrán simular los padres de un nodo  $X_i$  si éste es un nodo evidencia o si ya ha sido previamente muestreado. Los valores de  $pa(x_i)$  se generan en función de los parámetros probabilísticos  $p(x_i | pa(x_i))$  normalizados.

**Método de muestreo por importancia.** El método de muestreo por importancia [27, 116, 121] simula el valor de cada variable no observada a partir de una distribución de probabilidad  $f$  denominada *función de importancia*, definida sobre cada variable de la red. Existen distintos métodos de este tipo, que se diferencian por la forma de cálculo de la función de importancia. La convergencia hacia los resultados correctos será tanto más rápida cuanto más parecida sea la función de importancia utilizada a la distribución de probabilidades a posteriori que se pretende calcular.

En este método, el peso asociado a una muestra  $\mathbf{x}$  viene dado por la probabilidad a priori de  $\mathbf{x}$ ,  $P(\mathbf{x})$ , dividida por la probabilidad de seleccionar  $\mathbf{x}$  a partir de  $f$ .

**Método de muestreo de Markov.** El muestreo de Markov [105] genera inicialmente una muestra de forma aleatoria. A continuación se simulan secuencialmente las variables no observadas siguiendo un orden arbitrario hasta obtener otra muestra. La simulación de cada variable no observada  $X_i$  se realiza a partir de una función de probabilidad asociada, que depende únicamente del propio nodo  $X_i$  y de su *manto de Markov*, que está formado por sus padres, sus hijos y los demás padres de sus hijos.

En este método, los valores obtenidos en la última muestra sirven de base para hallar la próxima muestra. Además, no se requiere una ordenación de los nodos, ya que para las variables a las que no se les ha asignado todavía un nuevo valor en la simulación actual se utilizan los valores de la simulación previa. En este método, los pesos asociados a cada muestra son siempre la unidad.

### 4.1.2. Modelos canónicos

#### Puerta O probabilista

Una familia de nodos que interactúa de acuerdo al modelo de puerta O probabilista [106] está compuesta por  $n$  nodos padres o causas  $X_1, \dots, X_n$  y un nodo hijo o efecto  $Y$ . Tanto las causas como el efecto se representan mediante variables aleatorias binarias, que pueden tomar los valores *ausente* o *presente*.

En el modelo de puerta O probabilista, cada causa  $X_i$  actúa independientemente del resto de causas para producir el efecto  $Y$ . Para cada causa  $X_i$  presente, existe una determinada probabilidad de que no produzca el efecto o, dicho de otro modo, de que quede inhibida. Si dichas probabilidades fueran nulas, estaríamos en el caso de la puerta O determinista.

Se puede descomponer una puerta O probabilista del modo indicado en la figura 4.2. Cada variable auxiliar  $Z_i$  representa el hecho de que  $Y$  ha sido producida por  $X_i$ . Por tanto,  $Y = +y$  ( $Y$  está presente) cuando  $Z_i = +z_i$  para al menos algún  $i$ .

Los parámetros necesarios para definir el modelo de puerta O probabilista son los siguientes:

$$c_i \equiv P(+z_i \mid +x_i)$$

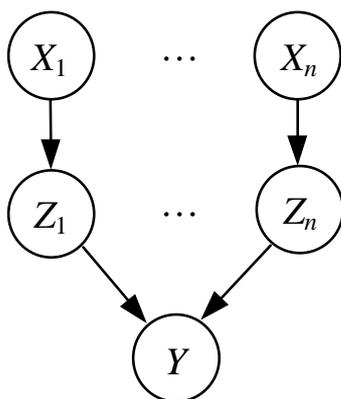


Figura 4.2: Puerta O probabilista con  $n$  causas.

En un modelo más detallado podríamos representar el mecanismo de inhibición asociado a cada causa mediante un segundo padre  $I_i$  de  $Z_i$ . De este modo,  $1 - c_i = P(\neg z_i \mid +x_i)$  es la probabilidad de que el inhibidor  $I_i$  actúe e impida que  $X_i$  cause  $Y$ . Si  $X_i$  estuviera ausente, no podría producir  $Y$ ; por tanto,

$$P(+z_i \mid \neg x_i) = 0$$

Para una determinada configuración de las variables  $X_i$ :

$$P(+y \mid \mathbf{x}) = 1 - \prod_{i \in T_{\mathbf{x}}} (1 - c_i)$$

donde  $T_{\mathbf{x}}$  es el subconjunto de causas de  $Y$  que están presentes.

### Puerta MAX probabilista

La puerta MAX probabilista [45, 48, 68] constituye una generalización para variables graduadas de la puerta O probabilista. Una variable graduada  $X$  es aquella que puede tomar un valor que representa ausencia o uno de entre  $g_X$  valores que hacen referencia a presencia con diferentes grados de intensidad creciente. Generalmente,  $X = 0$  significa “ $X$  está ausente” y los números enteros sucesivos indican mayores grados de intensidad. Por ejemplo, el concepto de *Fiebre* podría ser representado mediante una variable graduada con los siguientes valores: {*ausente* (0), *leve* (1), *moderada* (2), *severa* (3)}.

Este tipo de interacción causal puede ser modelada introduciendo  $n$  variables auxiliares  $Z_i$  que tomen valores en el mismo rango que el efecto  $Y$  (véase la figura 4.2). Los parámetros que requiere este modelo son las probabilidades condicionales siguientes:

$$c_y^{x_i} \equiv P(Z_i = y \mid X_i = x_i)$$

El valor que toma  $Y$  es el máximo de los  $z_i$ 's. Por tanto, la tabla de probabilidades condicionales (TPC) para  $Y$  está dada por:

$$P(y \mid \mathbf{x}) = \sum_{z \mid \max z = y} \prod_i c_{z_i}^{x_i} \quad (4.4)$$

La figura 4.3 muestra una representación gráfica de los cálculos definidos en la ecuación 4.4 para una familia con dos causas  $A$  y  $B$ , y un efecto  $C$ .

$P(C \mid A=a, B=b)$	$c_{Z_A=0}^{A=a}$	$c_{Z_A=1}^{A=a}$	$c_{Z_A=2}^{A=a}$	...	$c_{Z_A=g_C}^{A=a}$
$c_{Z_B=0}^{B=b}$	$C=0$	$C=1$	$C=2$	...	$C=g_C$
$c_{Z_B=1}^{B=b}$	$C=1$	$C=1$	$C=2$	...	$C=g_C$
$c_{Z_B=2}^{B=b}$	$C=2$	$C=2$	$C=2$	...	$C=g_C$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$
$c_{Z_B=g_C}^{B=b}$	$C=g_C$	$C=g_C$	$C=g_C$	...	$C=g_C$

Figura 4.3: Esquema gráfico del cálculo de la TPC asociada a una puerta MAX probabilista con dos causas y un efecto.

### Puerta Y probabilista

En la puerta Y probabilista [48], cada nodo padre  $X_i$  es interpretado como una condición para un efecto  $Y$ . Tanto los nodos padres como el nodo hijo son variables binarias. Existe un mecanismo inhibitorio asociado a cada condición de manera que incluso cuando  $X_i$  está presente,  $Y$  puede ser falsa con una cierta probabilidad, aunque el resto de condiciones se satisfagan. Una condición se satisface cuando está presente y no ha sido inhibida.

Este tipo de interacción puede ser modelada introduciendo una variable auxiliar  $Z_i$  para cada arco  $X_i \rightarrow Y$ . El valor  $+z_i$  representa el hecho de que la condición  $X_i$  está presente y no ha sido inhibida. Por tanto,  $Y = +y$  cuando  $Z_i = +z_i$  para todo  $i$ . Los parámetros del modelo son los siguientes:

$$h_i \equiv P(+z_i \mid +x_i)$$

La probabilidad condicional de  $Y$  puede ser calculada del siguiente modo:

$$P(+y \mid \mathbf{x}) = \begin{cases} \prod_i h_i & \text{para } \mathbf{x} = (+x_1, \dots, +x_n) \\ 0 & \text{en caso contrario} \end{cases}$$

El modelo conjuntivo que hemos descrito en la presente sección es también conocido como puerta Y probabilista sin sustitutos [48].

### Puerta MIN probabilista

La puerta MIN probabilista [45, 48] es una generalización para variables graduadas de la puerta Y probabilista. Al igual que la puerta MAX probabilista, la puerta MIN probabilista puede ser modelada por medio de la introducción de  $n$  variables auxiliares  $Z_i$  con el mismo rango de definición que el efecto  $Y$ . Los parámetros asociados a la relación entre  $X_i$  y  $Z_i$  son:

$$h_y^{x_i} \equiv P(Z_i = y \mid X_i = x_i)$$

El valor que toma  $Y$  es el mínimo de los  $z_i$ 's. Por tanto, la TPC del efecto  $Y$  se calcula del siguiente modo:

$$P(y \mid \mathbf{x}) = \sum_{z \mid \min z=y} \prod_i h_{z_i}^{x_i}$$

La figura 4.4 refleja gráficamente las operaciones definidas en la ecuación previa para una familia con dos condiciones  $A$  y  $B$ , y un efecto  $C$ .

### Puertas probabilistas residuales

En aplicaciones reales, normalmente no es factible enumerar todas las causas posibles de un efecto. En estos casos, las causas no explícitas pueden ser representadas implícitamente en una puerta O/MAX probabilista por medio de un vector

$P(C   A=a, B=b)$	$h_{Z_A=0}^{A=a}$	$h_{Z_A=1}^{A=a}$	$h_{Z_A=2}^{A=a}$	...	$h_{Z_A=g_C}^{A=a}$
$h_{Z_B=0}^{B=b}$	C=0	C=0	C=0	...	C=0
$h_{Z_B=1}^{B=b}$	C=0	C=1	C=1	...	C=1
$h_{Z_B=2}^{B=b}$	C=0	C=1	C=2	...	C=2
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$
$h_{Z_B=g_C}^{B=b}$	C=0	C=1	C=2	...	C= $g_C$

Figura 4.4: Esquema gráfico del cálculo de la TPC asociada a una puerta MIN probabilista con dos condiciones y un efecto.

de probabilidades residuales  $c_y^*$ , que establece la probabilidad de que  $Y = y$  cuando todas las causas explícitas del modelo están ausentes. Si  $Y$  es una variable aleatoria binaria, basta con proporcionar un único parámetro residual  $c_{+y}^*$ .

En interacciones de tipo conjuntivo, las condiciones no explícitas pueden ser representadas mediante un vector de parámetros residuales  $h_y^*$ , dando lugar a las puertas Y/MIN residuales.

## 4.2. Razonamiento temporal en inteligencia artificial

En esta sección examinaremos las técnicas más relevantes surgidas dentro del campo de la inteligencia artificial para la representación y razonamiento con conocimiento temporal. Para ello, primeramente realizamos la siguiente clasificación:

- métodos lógicos,
- métodos basados en restricciones temporales y
- métodos probabilistas.

### 4.2.1. Métodos lógicos

#### Cálculo de situaciones

McCarthy y Hayes [90] desarrollaron uno de los primeros trabajos reseñables sobre razonamiento temporal en el contexto de la inteligencia artificial. El *cálculo de situaciones* constituyó la primera representación basada en lógica que abordó la representación y razonamiento sobre conceptos temporales.

Una *situación* es considerada como “el estado del universo en un instante de tiempo”. En la práctica es imposible especificar todos los hechos que definen una situación cualquiera y, por tanto, generalmente aparece descrita de forma parcial. Cada uno de los hechos que se puede establecer en relación a una situación se expresa a través de un predicado de primer orden. Por ejemplo, el predicado *nevando(s)* indica que “está nevando en la situación *s*”.

Es importante conocer cómo se relacionan diferentes situaciones entre sí; en concreto, cómo cambia una situación para dar lugar a otra diferente. Para ello se utilizan *reglas causales*, cada una de las cuales determina los cambios producidos por un determinado tipo de *acción*. Una regla causal en el cálculo de situaciones define la diferencia existente entre la situación previa a una acción y la situación posterior a dicha acción. Cada regla causal consta de una precondición que contiene los hechos que se deben verificar para que la acción tenga lugar, así como de un efecto donde figuran los nuevos hechos que resultan después de la ejecución de la acción.

Uno de los inconvenientes a los que se enfrenta el cálculo de situaciones es el llamado *problema del marco*, que hace referencia a la dificultad de especificar, sobre todo en dominios del mundo real, qué cambia y qué no cambia en la descripción de un estado a medida que se ejecutan acciones o simplemente a medida que el tiempo transcurre.

#### Lógica temporal de McDermott

El cálculo de situaciones se basa en la definición de estados o situaciones, sin una representación directa del tiempo. Por el contrario, en gran parte del trabajo desarrollado con posterioridad, la tendencia predominante consistió en asociar instantes

o intervalos de tiempo a cada hecho.

En una representación explícita del tiempo, existe un conjunto totalmente ordenado de puntos temporales, cada uno de ellos asociado a un número. Si la línea del tiempo es isomorfa a los números enteros, tenemos un modelo discreto del tiempo. La duración entre puntos temporales sucesivos puede ser constante o variable, y tan larga o corta como se desee. Tendremos tiempo continuo cuando la línea del tiempo sea isomorfa a los números reales. Una diferencia entre estos dos modelos de tiempo radica en que con tiempo discreto se pueden definir las nociones de “el siguiente punto temporal” o “el siguiente instante de tiempo”. Este concepto no existe en el caso de un modelo continuo del tiempo, en el que se puede tener una secuencia infinita de puntos temporales ordenados entre otros dos dados. Normalmente se considera que el tiempo se extiende infinitamente hacia el futuro y hacia el pasado.

McDermott [91] fue probablemente el primer investigador dentro del campo de la inteligencia artificial en definir una *lógica temporal* que adoptara una representación explícita del tiempo. En la lógica temporal de McDermott, a cada hecho se le asocia un número real que indica un instante temporal en el que dicho hecho es cierto. Por tanto, se hace uso de una representación continua del tiempo.

McDermott introduce el concepto de *crónica* como una posible descripción de la historia completa de los elementos del universo de discurso, es decir, para cada punto temporal considerado, una asignación de valores “verdadero” o “falso” a todas las posibles proposiciones existentes en la teoría. Si se considerara únicamente un modelo del mundo, se tendría un tiempo de carácter lineal. Por el contrario, a partir del concepto de crónica la línea del tiempo puede dividirse en diferentes ramas.

En el modelo de McDermott es posible establecer que un hecho es cierto a lo largo del intervalo definido entre dos puntos temporales. También es posible definir eventos que tardan en producirse, no sólo un instante, sino un intervalo de tiempo.

Allen [3] desarrolló una lógica temporal basada en intervalos en vez de en puntos o instantes temporales. En el modelo de McDermott, un intervalo se define a partir de dos puntos temporales. Allen escoge el intervalo como primitiva temporal y representa puntos temporales a partir de la intersección de intervalos. Realmente no existe una diferencia sustancial en cuanto a las propiedades expresivas y computacionales de estos dos modelos.

La forma de abordar el problema del marco en la lógica temporal de McDermott consiste en suponer que un hecho sigue siendo válido en el tiempo, a no ser que explícitamente se sepa que deja de ser cierto. Más concretamente, se define un predicado “*persist*” que indica el límite temporal asociado a la veracidad de un hecho. Sin embargo, la selección de este límite temporal no es una tarea sencilla. Dado un hecho, generalmente son posibles varios límites, cada uno con una probabilidad diferente. El resultado anterior es un argumento a favor del uso de probabilidades en razonamiento temporal.

### Lógicas temporales modales

La lógica modal es una extensión de la lógica de predicados de primer orden, que introduce operadores modales. La semántica de la lógica modal está relacionada con la idea de mundos posibles [75], que son reinterpretados en el contexto temporal mediante la asociación a cada mundo de un determinado tiempo en que el universo puede ser descrito.

Los operadores temporales modales que típicamente se suelen introducir son:

$F\phi \equiv$  “ $\phi$  es verdadero en algún tiempo futuro”

$P\phi \equiv$  “ $\phi$  es verdadero en algún tiempo pasado”

$G\phi \equiv$  “ $\phi$  es verdadero en cualquier tiempo futuro”

$H\phi \equiv$  “ $\phi$  es verdadero en cualquier tiempo pasado”

Los diferentes mundos o elementos temporales se conectan a través de una relación de precedencia temporal,  $\prec$ . Variando las propiedades de esta relación, establecidas sintácticamente a partir de una serie de axiomas, se obtienen diferentes tipos de lógicas temporales modales.

La lógica temporal modal denominada  $K$  no impone restricciones sobre  $\prec$  y

queda definida por los axiomas siguientes:

$$G(\phi_1 \rightarrow \phi_2) \rightarrow (G\phi_1 \rightarrow G\phi_2)$$

$$H(\phi_1 \rightarrow \phi_2) \rightarrow (H\phi_1 \rightarrow H\phi_2)$$

$$\phi \rightarrow HF\phi$$

$$\phi \rightarrow GP\phi$$

$$G\phi, \text{ si } \phi \text{ es un axioma}$$

$$H\phi, \text{ si } \phi \text{ es un axioma}$$

La lógica  $K_c$  [33] se obtiene imponiendo la transitividad del tiempo:

$$\forall t, t', t'' \quad ((t \prec t') \wedge (t' \prec t'')) \rightarrow (t \prec t'')$$

lo que se define axiomáticamente de la siguiente forma:

$$FF\phi \rightarrow F\phi$$

$$PP\phi \rightarrow P\phi$$

También se puede imponer la condición de que no pueden existir pasados diferentes:

$$\forall t, t', t'' \quad ((t \prec t'') \wedge (t' \prec t'')) \rightarrow ((t \prec t') \vee (t = t') \vee (t' \prec t))$$

lo cual se expresa sintácticamente mediante este axioma:

$$(P\phi_1 \wedge P\phi_2) \rightarrow (P(\phi_1 \wedge \phi_2) \vee P(\phi_1 \wedge P\phi_2) \vee P(P\phi_1 \wedge \phi_2))$$

que define la lógica  $K_b$  de Rescher y Urquhart [112].

### 4.2.2. Métodos basados en restricciones temporales

En ciertas ocasiones sólo es posible disponer de información temporal relativa e incompleta en forma de restricciones. Una restricción temporal limita el conjunto de posibles valores temporales que pueden ser asignados a dos entidades. Por ejemplo, “el instante  $t_2$  es posterior al instante  $t_1$ ” limita el conjunto de valores que puede tomar el par  $(t_1, t_2)$ .

Una forma de abordar problemas temporales en inteligencia artificial consiste en representarlos como un *problema de satisfacción de restricciones*, donde cada restricción tiene un significado temporal. La resolución de un problema de satisfacción de restricciones consiste en asignar valores a un conjunto de variables sujetas a una serie de restricciones [41, 43, 44, 97]. Una restricción se suele representar mediante conocimiento de carácter declarativo y local, referente a un subconjunto reducido del conjunto total de variables que puede llegar a manejar un sistema.

Un problema de satisfacción de restricciones se formula a partir de los siguientes elementos:

1. Un conjunto finito de variables  $\{V_1, \dots, V_n\}$  que respectivamente pueden tomar valores en los dominios  $\{D_1, \dots, D_n\}$ .
2. Un conjunto finito de restricciones  $\{R_1, \dots, R_r\}$  establecidas en relación a las variables anteriores. Una restricción  $n$ -aria sobre dichas variables es un subconjunto del producto cartesiano  $D_1 \times D_2 \times \dots \times D_n$ . Las relaciones unitarias y binarias son casos particulares de relaciones  $n$ -arias. Una restricción unitaria limita los valores de una variable a un subconjunto de su dominio:

$$R_i \subseteq D_i$$

Una restricción binaria limita los valores de un par de variables:

$$R_{i,j} \subseteq D_i \times D_j$$

Una *red de relaciones binarias* está formada por los siguientes elementos: un conjunto de variables  $\{V_1, \dots, V_n\}$  y un conjunto de restricciones binarias o unitarias sobre esas variables. Una solución de la red es cualquier  $n$ -tupla  $(v_1, \dots, v_n)$  que cumpla todas las restricciones:

$$\forall i \forall j \quad (v_i \in R_i) \wedge ((v_i, v_j) \in R_{i,j})$$

Una red de relaciones binarias se puede representar mediante un grafo en el que los nodos correspondan a variables y los arcos a restricciones. El conjunto de todas las soluciones de una red de relaciones binarias define una restricción  $n$ -aria. Por el contrario, no toda restricción  $n$ -aria se puede expresar únicamente por medio de restricciones unitarias y binarias [41].

	<	=	>
<	<	<	?
=	<	=	>
>	?	>	>

Tabla 4.1: Composición de relaciones primitivas entre instantes.

Las técnicas para la resolución de problemas de satisfacción de restricciones permiten: comprobar si existe al menos una solución en la red, verificar si una  $n$ -tupla dada puede ser solución, encontrar una solución cualquiera de la red, encontrar todas las soluciones de la red o reducir al mínimo los dominios de posibles valores para cada variable de acuerdo a las restricciones impuestas en la red. Este último aspecto es de especial interés en problemas temporales.

El método de resolución más elemental consistiría en la aplicación de un algoritmo de retroceso. Sin embargo, existen variantes de este algoritmo (esquemas de proyección o *lookahead*, de retrosección o *lookback*, etc.) que permiten mejorar la eficiencia computacional del mismo.

En un modelo de restricciones temporales, los nodos representan instantes o intervalos y los arcos relaciones temporales entre instantes o entre intervalos. En un modelo de relaciones temporales cualitativas entre instantes de tiempo, se pueden definir tres relaciones primitivas cualitativas: *antes* (<), *igual* (=) y *después* (>). De cualquier modo, la información disponible sobre dos instantes de tiempo puede ser incompleta. El conocimiento incompleto se puede expresar mediante disyunciones lógicas de relaciones primitivas:  $(t_1 < t_2) \vee (t_1 = t_2)$ . Se puede establecer un álgebra de puntos a partir del conjunto de todas las posibles relaciones binarias cualitativas entre instantes:  $\{<, =, >, \leq, \geq, \neq, ?, \emptyset\}$ , sobre el que se definen dos operaciones: intersección y composición. La tabla 4.1 muestra el resultado de la composición entre relaciones primitivas.

Allen [3] introdujo un modelo de razonamiento temporal para relaciones cualitativas entre intervalos. La formalización de un álgebra de intervalos es similar a la de un álgebra de puntos. Allen definió trece posibles relaciones entre intervalos. En la figura 4.5 se muestran siete de ellas. Las seis restantes son las relaciones inversas a las que aparecen en la figura.

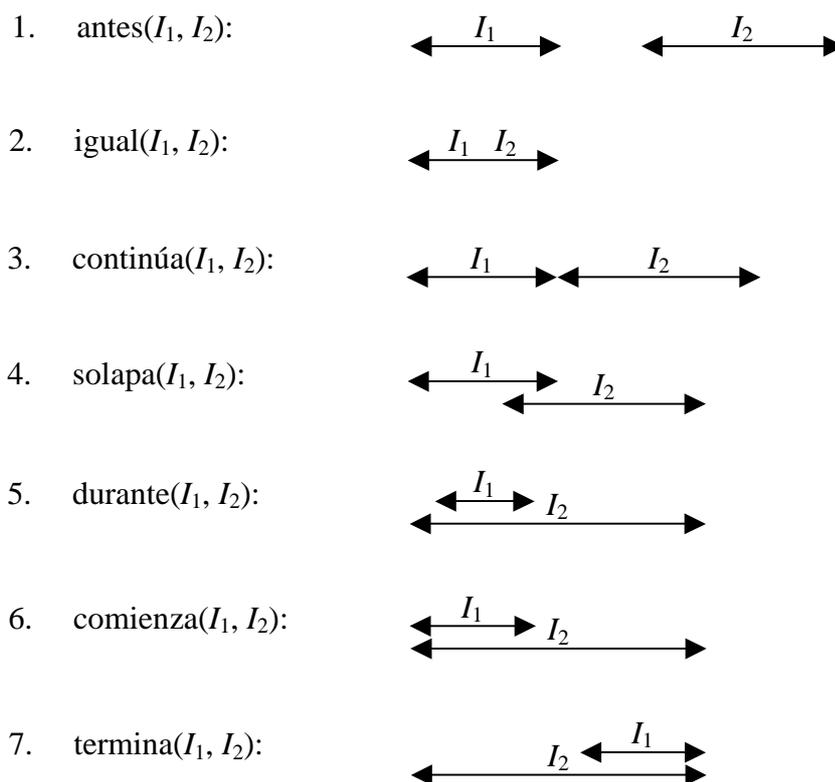


Figura 4.5: Posibles relaciones entre dos intervalos.

### 4.2.3. Métodos probabilistas

Existen modelos pertenecientes al campo del razonamiento temporal probabilista que se han aplicado a dominios caracterizados por la presencia de procesos dinámicos. Estos modelos permiten resolver tareas de predicción, diagnóstico, monitorización, planificación, etc.

Por su relación con el trabajo desarrollado en la presente tesis doctoral, nos ocupamos en esta sección de los *modelos dinámicos markovianos parcialmente observables* (véase la figura 4.6).

En un modelo dinámico markoviano parcialmente observable se consideran dos tipos de variables: *variables de estado* ( $X_t$ ) y *variables evidencia* ( $O_t$ ). Mientras que las primeras permanecen ocultas, las segundas son siempre observables. Cada variable está asociada a un instante discreto de tiempo.

Normalmente conoceremos los valores que toman las variables observables y es-

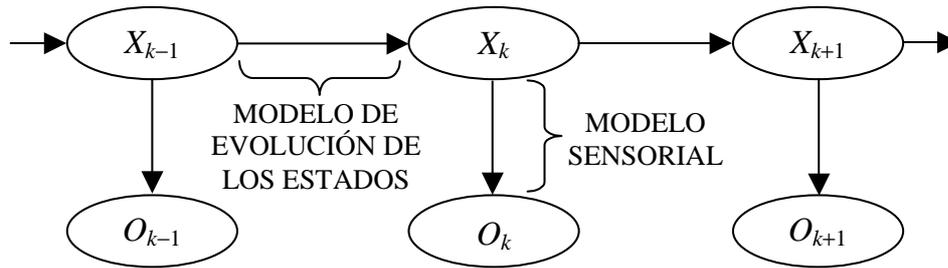


Figura 4.6: Representación gráfica de un modelo dinámico markoviano parcialmente observable.

taremos interesados en calcular las probabilidades a posteriori de las variables de estado. Para ello hay que tener en cuenta el carácter markoviano de este modelo, es decir, el futuro es condicionalmente independiente del pasado una vez que conocemos el presente. Esta propiedad se traduce en las siguientes igualdades:

$$P(\mathbf{x}_k \mid \mathbf{x}_0, \dots, \mathbf{x}_{k-1}, \mathbf{o}_0, \dots, \mathbf{o}_k) = P(\mathbf{x}_k \mid \mathbf{x}_{k-1}, \mathbf{o}_k)$$

$$P(\mathbf{o}_k \mid \mathbf{x}_0, \dots, \mathbf{x}_k, \mathbf{o}_0, \dots, \mathbf{o}_{k-1}) = P(\mathbf{o}_k \mid \mathbf{x}_k)$$

Los parámetros numéricos que completan un modelo dinámico markoviano parcialmente observable corresponden al *modelo de evolución de los estados*,  $P(\mathbf{x}_k \mid \mathbf{x}_{k-1})$ , y al *modelo sensorial*,  $P(\mathbf{o}_k \mid \mathbf{x}_k)$ . Se suele suponer que estos parámetros son iguales para todos los instantes de tiempo considerados.

Dos de los problemas típicos que se abordan en este modelo son el de *monitorización* (determinación del estado actual del sistema dada la evidencia acumulada hasta el momento) y el de *predicción* (determinación del estado futuro del sistema dada la evidencia acumulada hasta el momento). La predicción puede ser estudiada como una extensión directa del proceso de monitorización; por tanto, a continuación nos ocuparemos únicamente de este último tipo de problemas.

En un proceso de monitorización, pretendemos conocer las probabilidades a posteriori de las variables de estado en el instante actual,  $k$ :

$$P(\mathbf{x}_k \mid \mathbf{o}_0, \dots, \mathbf{o}_k)$$

A partir del teorema de Bayes y de las relaciones de independencia condicional

implícitas en el modelo:

$$P(\mathbf{x}_k \mid \mathbf{o}_0, \dots, \mathbf{o}_k) = \alpha \cdot P(\mathbf{o}_k \mid \mathbf{x}_k) \cdot \sum_{\mathbf{x}_{k-1}} P(\mathbf{x}_k \mid \mathbf{x}_{k-1}) \cdot P(\mathbf{x}_{k-1} \mid \mathbf{o}_0, \dots, \mathbf{o}_{k-1})$$

donde  $\alpha$  es una constante de normalización. Esta expresión tiene carácter recursivo y permite, partiendo del instante inicial, calcular las probabilidades a posteriori de las variables de estado en el instante actual.

En algunos problemas nos interesará conocer la influencia de evidencias pasadas, presentes y futuras sobre las variables de estado actuales. Esto se conoce con el nombre de *suavizado* en la teoría de control. En este caso tendríamos:

$$P(\mathbf{x}_k \mid \mathbf{o}_0, \dots, \mathbf{o}_k, \mathbf{o}_{k+1}, \dots, \mathbf{o}_N) = \alpha \cdot P(\mathbf{x}_k \mid \mathbf{o}_0, \dots, \mathbf{o}_k) \cdot P(\mathbf{o}_{k+1}, \dots, \mathbf{o}_N \mid \mathbf{x}_k)$$

donde el penúltimo factor de la expresión anterior es el mismo que aparecería en el caso de monitorización. Respecto al último factor,

$$P(\mathbf{o}_{k+1}, \dots, \mathbf{o}_N \mid \mathbf{x}_k) = \sum_{\mathbf{x}_{k+1}} P(\mathbf{o}_{k+1} \mid \mathbf{x}_{k+1}) \cdot P(\mathbf{x}_{k+1} \mid \mathbf{x}_k) \cdot P(\mathbf{o}_{k+2}, \dots, \mathbf{o}_N \mid \mathbf{x}_{k+1})$$

que se puede calcular de forma recursiva retrocediendo en el tiempo.

Si en un modelo dinámico markoviano parcialmente observable las variables pertenecientes a un determinado instante forman una red bayesiana, tendríamos un nuevo modelo que recibe el nombre de *red bayesiana dinámica* (véase la sección 4.3.1).

### 4.3. Representación explícita del tiempo en redes bayesianas

Por regla general, las redes bayesianas se han aplicado sin introducir una representación explícita del tiempo en las mismas. No obstante, a lo largo de los últimos años han surgido una serie de trabajos encaminados al modelado de procesos temporales por medio de redes bayesianas. Dichos trabajos han dado lugar a la aparición de una serie de formalismos que pueden ser clasificados, atendiendo a la primitiva temporal que utilizan, en los siguientes grupos:

- formalismos basados en el empleo de **instantes** como primitiva temporal,
- formalismos basados en **intervalos** y
- formalismos basados en la representación del tiempo como una variable **continua**.

#### 4.3.1. Formalismos basados en instantes

El modo más ampliamente extendido de aplicar redes bayesianas a dominios dinámicos consiste en discretizar el tiempo y crear una réplica de cada variable aleatoria para cada punto temporal.

En el formalismo de *red bayesiana dinámica* (RBD) [38, 40, 74, 101], en un principio se construye un modelo causal estático del dominio. Seguidamente se genera una copia de dicho modelo estático para cada instante de tiempo perteneciente a un determinado rango temporal de interés. Finalmente se establecen conexiones entre nodos pertenecientes a redes estáticas consecutivas (véase la figura 4.7). De este modo, una red bayesiana dinámica cumple la *propiedad de Markov*: el futuro es condicionalmente independiente del pasado dado el presente. (Esta propiedad no debe ser confundida con la condición de Markov que se aplica en la definición formal de una red bayesiana, aunque ambas están muy relacionadas.)

En una red bayesiana dinámica se puede llevar a cabo diagnóstico y predicción por medio de los algoritmos habituales de inferencia que se aplican en redes bayesianas generales. Sin embargo, en el caso de secuencias de observaciones muy extendidas en el tiempo, la propagación de la evidencia en redes bayesianas dinámicas estructuralmente complejas se convierte en irrealizable [9].

Algunos ejemplos de la aplicación de redes bayesianas dinámicas a dominios reales son: un modelo para razonar sobre causalidad y persistencia de proposiciones, de Dean y Kanazawa [40], un modelo para la validación de sensores, de Nicholson y Brady [101], un método para razonamiento con redes bayesianas dinámicas, de Kjærulff [74], un sistema para la predicción de la apnea del sueño, de Dagum y Galper [37], un sistema de ayuda a la planificación de terapia en diabetes gestacional, de Hernando *et al.* [69], etc.

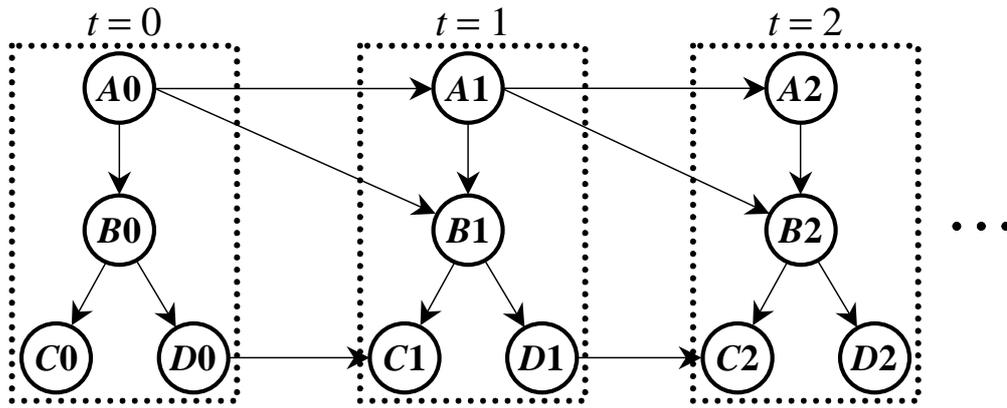


Figura 4.7: Ejemplo de red bayesiana dinámica.

### 4.3.2. Formalismos basados en intervalos

Arroyo Figueroa y Súcar [6, 7] proponen un modelo llamado *red bayesiana con nodos temporales* (RBNT). En este tipo de red bayesiana, cada nodo temporal representa un evento o el cambio de estado de una variable. Cada evento o cambio de estado asociado a un nodo temporal se puede producir como máximo una vez a lo largo del tiempo. El valor que toma una variable representa el intervalo de tiempo en que ocurre el cambio de estado o evento. Para cada nodo temporal se discretiza el rango temporal de interés en un número finito de intervalos, aunque el número de intervalos y su duración puede variar de un nodo a otro (granularidad variable). Cada intervalo definido en un nodo hijo representa los posibles retardos entre la ocurrencia de uno de sus eventos padre y el correspondiente cambio de estado del nodo hijo. Por tanto, en este modelo se hace uso de tiempos relativos para la definición de los valores asociados a cada nodo temporal. Por ejemplo, en la figura 4.8 el evento  $C$  se puede producir entre 4 y 7 unidades temporales después de la ocurrencia de  $A$ , o entre 7 y 12 unidades temporales después de que  $B$  haya tenido lugar.

Existe cierta asimetría en la forma de introducir evidencia en una red bayesiana de Arroyo Figueroa y Súcar: mientras que la ocurrencia de un evento asociado a un nodo sin padres constituye evidencia directa, en el caso de que haya tenido lugar un evento asociado a un nodo con padres serían posibles diferentes escenarios. Por otra parte, al ser detectado un evento inicial, su tiempo de ocurrencia fijaría temporalmente la red.

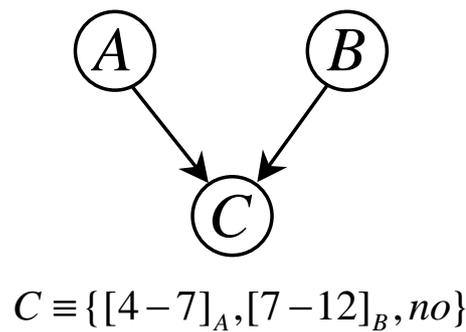


Figura 4.8: Valores asociados a un nodo temporal  $C$ .

Una red bayesiana con nodos temporales permite razonar sobre la probabilidad de ocurrencia de un conjunto de eventos a partir de técnicas de propagación de la evidencia desarrolladas para redes bayesianas generales. Dichas técnicas se pueden aplicar en tareas de diagnóstico y predicción. Sin embargo, este modelo carece de una formalización de modelos canónicos para procesos temporales. Por otra parte, cada valor que puede tomar un nodo efecto, asociado a un determinado intervalo de tiempo, significa que el efecto ha sido causado en ese intervalo únicamente por uno de sus nodos padre. Esta hipótesis es poco realista en muchos dominios de aplicación, donde la evidencia sobre la ocurrencia de un evento puede ser explicada por varias de sus causas. Como ejemplo de lo anterior, considérese la distribución temporal para los eventos  $A$ ,  $B$  y  $C$  que aparece en la figura 4.9. Dada dicha distribución temporal, el primer valor que puede tomar  $C$  es cierto ya que el retardo real entre  $A$  y  $C$  (5 unidades de tiempo) está incluido dentro del intervalo  $[4, 7]$ . Pero también el segundo valor que puede tomar  $C$  es cierto, ya que el retardo entre  $B$  y  $C$  (10 unidades de tiempo) está incluido dentro del intervalo  $[7, 12]$ .

Dentro de los formalismos basados en intervalos, Santos y Young [117] desarrollan una técnica denominada *red temporal probabilista*, que permite la representación de causalidad sujeta a restricciones temporales. Las redes bayesianas proporcionan la base probabilista de este modelo, mientras que el tratamiento del tiempo se basa en el sistema de intervalos de Allen [3] y sus trece relaciones.

Las redes temporales probabilistas modelan procesos y la interacción entre los mismos. El estado de un proceso se representa por medio de un valor en un intervalo de tiempo dado. Un proceso puede ser definido a lo largo de cualquier número de

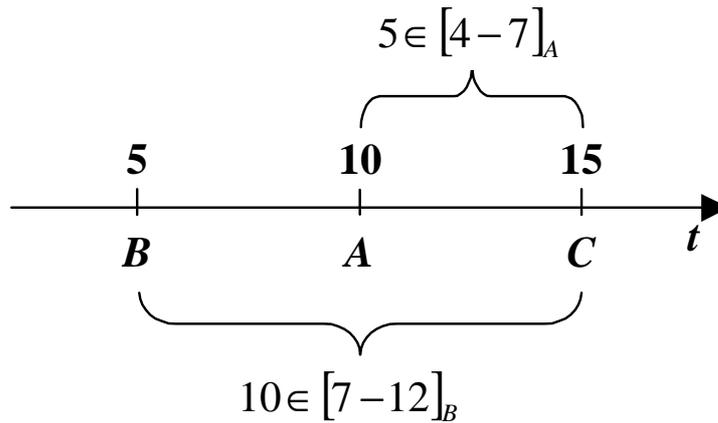


Figura 4.9: Posible distribución temporal de los eventos  $A$ ,  $B$  y  $C$  de la figura 4.8.

tales intervalos. Los nodos de una red temporal probabilista se denominan *agregados temporales*. Un agregado temporal consta de un conjunto de estados que puede tomar su proceso asociado, junto con un conjunto de intervalos temporales. Cada intervalo tiene asociada una variable aleatoria que hace referencia al estado del proceso a lo largo de ese intervalo. Se podría asignar el mismo valor a variables aleatorias diferentes pertenecientes al mismo agregado temporal.

En este modelo, los enlaces constituyen relaciones causales temporales entre agregados temporales. Cada enlace de la red consta de un conjunto de carácter disyuntivo de relaciones entre intervalos ( $=$ ,  $>$ ,  $<$ , etc.) y un esquema (OR, XOR o PASSTHROUGH), que establecen qué combinaciones concretas de intervalos son posibles o no. Esto permite la definición exacta de los intervalos en que el estado de un proceso afecta a otro proceso.

La tarea principal en este método es encontrar el estado más probable de las variables de la red dada cierta evidencia. La explicación más probable de la evidencia es aquella asignación completa de valores que hace máximo el valor de la probabilidad conjunta, que en este modelo se computa aplicando la regla de la cadena.

### 4.3.3. Formalismos basados en tiempo continuo

Berzuini [8] asocia una densidad de probabilidad a cada variable aleatoria temporal para representar tiempo continuo. Cada variable aleatoria hace referencia a

un evento supuestamente instantáneo. Añadida a cada arco existe una distribución condicional especificada como una intensidad condicional, que expresa cómo la intensidad de un evento efecto varía en función del tiempo transcurrido desde la ocurrencia de un evento-causa. La intensidad de un evento en el instante  $t$  indica su propensión a ocurrir justo después de  $t$ , dado que no ocurrió previamente. En presencia de varias causas, éstas contribuyen con funciones de regresión separadas que se combinan aditivamente para producir la intensidad condicional del efecto. Mediante una apropiada discretización de las variables continuas existentes, se pueden aplicar técnicas exactas para realizar inferencia. Otra posibilidad es utilizar métodos aproximados de simulación estocástica, los cuales no requieren la discretización de las variables aleatorias temporales.

Kanazawa [72] define un formalismo basado en el tipo de redes propuesto por Berzuini. Este formalismo, además de utilizar tiempo continuo para representar la ocurrencia de eventos, permite modelar cualquier hecho por medio de la representación del instante en que empieza a satisfacerse y del instante en que deja de satisfacerse. Las influencias condicionales se representan por medio de funciones paramétricas simples. Existe la posibilidad de hacer uso de un amplio abanico de distribuciones paramétricas para modelar las densidades de probabilidad asociadas a eventos y hechos.

#### 4.3.4. Recapitulación

La tabla 4.2 muestra una clasificación de los diferentes tipos de redes bayesianas para razonamiento temporal que hemos presentado. La clasificación se ha realizado de acuerdo a dos criterios:

- primitiva temporal utilizada y
- número de ocurrencias permitido para cada evento a lo largo del tiempo.

En esta tabla hemos incluido también la *red de eventos probabilistas en tiempo discreto* (REPTD), de la que hablaremos en el próximo capítulo. Hemos incluido la REPTD entre los métodos diseñados para procesos irreversibles, aunque es posible utilizarla, con cierta dificultad, para representar procesos reversibles.

	<i>Instantes</i>	<i>Intervalos</i>	<i>Tiempo continuo</i>
<i>Procesos irreversibles</i>	<b>REPTD</b> (Galán, Díez)	<b>RBNT</b> (Arroyo, Súcar)	<b>Network of dates</b> (Berzuini) <b>Continuous time net</b> (Kanazawa)
<i>Procesos generales</i>	<b>RBD</b> (Dean, Kanazawa)	<b>RTP</b> (Santos, Young)	

Tabla 4.2: Clasificación de redes bayesianas aplicadas a razonamiento temporal.

## Capítulo 5

# Redes de eventos probabilistas en tiempo discreto

En una *red de eventos probabilistas en tiempo discreto* (REPTD) [59] cada variable representa un evento, es decir, un cambio de estado. Consideramos que el evento asociado a una variable de la red puede ocurrir únicamente una vez a lo largo del tiempo. De este modo, cualquier proceso irreversible tiene una representación inmediata en este modelo mediante la introducción de una variable para cada evento que forma parte del proceso. Un proceso reversible en el que un evento puede repetirse en el tiempo, se puede representar a partir de varias variables, una para cada cambio de estado sucesivo; por ejemplo, el proceso de encender y apagar una luz dos veces consta de cuatro eventos. Discretizamos el tiempo adoptando la unidad temporal adecuada para cada caso (segundos, días, meses, etc.); por tanto, la granularidad temporal del modelo depende del problema particular que estemos intentando resolver. El valor que toma una variable indica el momento en que su evento asociado ocurre.

Formalmente, una variable aleatoria temporal  $V$  de la red puede tomar un conjunto de valores  $v[i]$  con  $i \in \{a, \dots, b, nunca\}$ , donde  $a$  y  $b$  son los instantes o intervalos que definen los límites del rango temporal de interés para  $V$ . Por ejemplo, si  $V$  representara “ser ingresado en el hospital”,  $V = v[a]$  significaría que el paciente ha sido ingresado en el instante o intervalo  $a$ . Si el paciente no hubiera sido finalmente ingresado en el hospital entonces  $V = v[nunca]$ . Los enlaces de la red

representan mecanismos causales temporales entre nodos. Por tanto, cada TPC da idea de cuáles son los retardos más probables entre los eventos padres y el evento hijo. En el caso de una interacción dinámica general en una familia de nodos, definir la TPC implica establecer la probabilidad de ocurrencia del nodo hijo a lo largo del tiempo, dada cualquier configuración temporal de los eventos padre. En una familia de  $n$  padres  $X_1, \dots, X_n$  y un hijo  $Y$ , la TPC viene dada por

$$P(y[t_Y] \mid x_1[t_1], \dots, x_n[t_n])$$

con

$$t_Y \in \{0, \dots, n_Y, nunca\}, t_i \in \{0, \dots, n_i, nunca\}$$

La probabilidad conjunta de las variables de la red se obtiene a partir del producto de todas las TPCs. Cualquier probabilidad marginal o condicional puede ser calculada a partir de la probabilidad conjunta. Por ejemplo, si  $B$  hubiera ocurrido en  $t_1$  y  $C$  en  $t_2$ , la probabilidad a posteriori para  $A$  sería

$$P(a[t] \mid b[t_1], c[t_2]) = \frac{P(a[t], b[t_1], c[t_2])}{P(b[t_1], c[t_2])}$$

Esta expresión puede ser utilizada para tareas de diagnóstico o predicción en la red.

En muchos dominios del mundo real, las relaciones causales dinámicas presentes cumplen la propiedad de *invariancia temporal*:

$$P(y[t_Y + \Delta t] \mid x_1[t_1 + \Delta t], \dots, x_n[t_n + \Delta t]) = P(y[t_Y] \mid x_1[t_1], \dots, x_n[t_n])$$

Si todas las TPCs de la red son invariantes frente al tiempo, la red en su totalidad también lo será.

## 5.1. Tiempo absoluto vs. tiempo relativo

Dada una variable temporal  $V$  que puede tomar valores:

$$\{v[i]\} \quad \text{con } i \in \{a, \dots, b, nunca\},$$

el índice temporal  $i$  puede representar un tiempo absoluto o un tiempo relativo. En el segundo caso, el tiempo de referencia (tiempo cero) lo marca la ocurrencia de un evento particular  $V_{\text{ref}}$  respecto al cual se definen los posibles tiempos de aparición

del resto de eventos considerados. Normalmente, una variable temporal definida mediante tiempo absoluto tendrá un mayor número de valores que otra definida mediante tiempo relativo. Esto es así debido a que, en el caso de tiempo relativo, el intervalo de los posibles retardos entre la aparición de  $V_{\text{ref}}$  y la aparición de la variable considerada puede ser corto, mientras que con tiempo absoluto cada variable puede tomar valores en un rango temporal que en general será largo. Debido a este hecho, el empleo de tiempo relativo tiene la ventaja de conducir a redes menos complejas donde cada variable toma menos valores; por el contrario, si no se conociera con certeza el tiempo absoluto de ocurrencia de  $V_{\text{ref}}$ , habría que manejar diferentes escenarios, cada uno de ellos referente a un posible tiempo absoluto de ocurrencia para  $V_{\text{ref}}$ . Esto último complica el modelo respecto al caso de tiempo absoluto, en el que no es necesario manejar escenarios.

Si bien en el presente capítulo hacemos referencia exclusivamente a tiempo absoluto, empleamos las dos alternativas en la parte final de la memoria, que trata de dos tipos de aplicaciones:

- En el capítulo 7 desarrollamos una red de gran complejidad para un dominio médico, por lo que estamos más interesados en la eficiencia computacional del proceso inferencial. Por tanto, usamos inicialmente un modelo con tiempo relativo<sup>1</sup>.
- En el capítulo 8 desarrollamos una red de menor complejidad para un dominio industrial, lo cual nos permitió el uso de tiempo absoluto.

## 5.2. **Nodo temporal sin padres**

Sea  $A$  un nodo evento que puede tener lugar en uno de los instantes o intervalos  $0, 1, 2, \dots$  en que hemos discretizado el rango temporal de interés. La distribución de probabilidad  $P(a[t])$  podría ser dada explícitamente. Otra forma alternativa de determinar esta distribución consiste en definir  $P(a^\dagger[t])$  como la probabilidad de que  $A$  sea verdadero en  $t$  dado que es falso en  $0, 1, \dots$  y  $t - 1$ ; es decir, la probabilidad de

---

<sup>1</sup>Recientemente hemos podido introducir tiempo absoluto en esta red médica gracias al empleo de la factorización descrita en la sección 5.8.1.

que  $A$  ocurra en el instante o intervalo  $t$  si no ha ocurrido antes de  $t$ . Estos valores pueden ser obtenidos a partir de una base de datos o pueden ser estimados por un experto humano. Como ejemplo de lo anterior,  $A$  podría representar la “muerte causada por una enfermedad epidémica” y  $P(a^\dagger[t])$  sería el porcentaje de población que muere semanalmente como consecuencia de la enfermedad (si el tiempo fuera discretizado en semanas). La probabilidad asociada al nodo temporal  $A$  se puede calcular multiplicando  $P(a^\dagger[t])$  por la probabilidad de que  $A$  no haya ocurrido antes de  $t$ :

$$P(a[t]) = P(a^\dagger[t]) \cdot \left( 1 - \sum_{t'=0}^{t-1} P(a[t']) \right) \quad \forall t > 0 \quad (5.1)$$

En el campo del *análisis de supervivencia* (véase [35, 130]),  $P(a^\dagger[t])$  recibe el nombre de *función de riesgo* y el segundo factor de la ecuación 5.1 es la *función de supervivencia* del evento  $A$ . La ecuación 5.1 es especialmente útil cuando  $P(a^\dagger[t])$  es una constante y no depende de  $t$ . Si  $P(a^\dagger[t]) = k$ , la ecuación 5.1 se transforma en:

$$P(a[t]) = (1 - k) \cdot P(a[t - 1]) \quad \forall t > 0 \quad (5.2)$$

**Demostración:**

$$\begin{aligned} P(a[t]) &= k \cdot \left( 1 - \left[ \sum_{t'=0}^{t-2} P(a[t']) \right] - P(a[t - 1]) \right) \\ &= P(a[t - 1]) - k \cdot P(a[t - 1]) \\ &= (1 - k) \cdot P(a[t - 1]) \end{aligned}$$

■

A partir de la ecuación 5.2,

$$P(a[t]) = (1 - k)^t \cdot k$$

Por tanto,  $P(a[t])$  es una distribución de probabilidad con decaimiento exponencial.

Al ser

$$(1 - k)^t = 1 - kt - \frac{1}{2}k^2t^2 + \dots$$

cuando  $kt \ll 1$  en el rango temporal de interés,  $(1 - k)^t \approx 1$ ; por tanto,  $P(a[t]) \approx k$ . Entonces tenemos, de forma aproximada, invariancia temporal para el nodo  $A$ .

### 5.3. Nodo temporal con un padre

Consideremos la red de la figura 5.1, donde suponemos que  $A$  es la única causa de  $B$ .

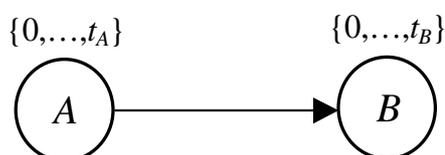


Figura 5.1: Red temporal con un padre y un hijo.

Los rangos temporales de interés de los eventos  $A$  y  $B$  son respectivamente  $\{0, \dots, t_A\}$  y  $\{0, \dots, t_B\}$ .  $P(b[j] | a[i])$  es la probabilidad de que  $B$  ocurra en  $j$  dado que  $A$  ha ocurrido en  $i$ . La TPC del enlace  $A \rightarrow B$  puede ser completamente general, permitiendo cualquier retardo entre  $A$  y  $B$ , con probabilidades que varíen a lo largo del tiempo para cada retardo particular (véase la tabla 5.1). Cuando  $j < i$ ,  $P(b[j] | a[i]) = 0$  ya que el efecto no puede preceder a la causa. Por otra parte, cuando  $i = \text{nunca}$ , también  $P(b[j] | a[i]) = 0$  porque si no ocurre la causa, tampoco ocurre el efecto. Si la relación causal del arco  $A \rightarrow B$  fuera invariante en el tiempo, entonces

$$P(b[j + \Delta t] | a[i + \Delta t]) = P(b[j] | a[i])$$

con

$$j, j + \Delta t \in \{0, \dots, t_B\} \quad \text{e} \quad i, i + \Delta t \in \{0, \dots, t_A\}$$

En este caso, únicamente necesitamos especificar una probabilidad para cada retardo.

$B \setminus A$	$a[0]$	$a[1]$	$a[2]$	$a[\text{nunca}]$
$b[0]$	0.5	0	0	0
$b[1]$	0.1	0.3	0	0
$b[2]$	0.1	0.05	0.2	0
$b[3]$	0.1	0.02	0.2	0
$b[\text{nunca}]$	0.2	0.63	0.6	1

Tabla 5.1: Una TPC general para  $t_A=2$  y  $t_B=3$ .

$B \setminus A$	$a[0]$	$a[1]$	$a[2]$	$a[nunca]$
$b[0]$	0.5	0	0	0
$b[1]$	0.1	0.5	0	0
$b[2]$	0	0.1	0.5	0
$b[3]$	0	0	0.1	0
$b[nunca]$	0.4	0.4	0.4	1

Tabla 5.2: TPC invariante en el tiempo con dos retardos, para  $t_A=2$  y  $t_B=3$ .

Existen dos casos especiales de invariancia temporal que merecen ser tenidos en cuenta:

- **Retardos limitados en el tiempo**

En este caso existe un número finito de posibles retardos entre la ocurrencia del evento padre y la ocurrencia del evento hijo. Por ejemplo, una vez que sabemos que  $A$  ha tenido lugar, la probabilidad de  $B$  podría ser 0.5 en ese instante o intervalo y 0.1 en el siguiente:

$$P(b[j] | a[i]) = \begin{cases} 0.5 & \text{si } j = i \\ 0.1 & \text{si } j = i + 1 \\ 0 & \text{en otro caso} \end{cases}$$

Las probabilidades condicionales del arco  $A \rightarrow B$  para este ejemplo aparecen en la tabla 5.2. Esta tabla muestra que los posibles retardos entre causa y efecto son 0 y 1, con probabilidades asociadas de 0.5 y 0.1, respectivamente. Estas probabilidades pueden ser estimadas por un experto humano u obtenidas de una base de datos.

- **Decaimiento exponencial**

Del mismo modo que las probabilidades a priori de un nodo  $A$  sin padres pueden ser especificadas directamente o a través de los parámetros  $P(a^\dagger[t])$ , también podemos especificar  $P(b[t] | a[i])$  directamente, como hemos hecho hasta ahora, o definiendo los parámetros  $P(b^\dagger[t] | a[i])$ , que representan la probabilidad de que  $B$  ocurra en el instante  $t$  dado que  $A$  ha ocurrido en  $i$  y

$B$  no ha tenido lugar antes de  $t$ . Al ser  $A$  la única causa de  $B$ ,

$$P(b[t] | a[i]) = \begin{cases} P(b^\dagger[t] | a[i]) \cdot (1 - \sum_{t'=i}^{t-1} P(b[t'] | a[i])) & \text{si } t > i \\ P(b^\dagger[t] | a[i]) & \text{si } t = i \\ 0 & \text{si } t < i \end{cases} \quad (5.3)$$

La ecuación 5.3 es equivalente matemáticamente a la ecuación 5.1. Si

$$\forall t \geq i \quad P(b^\dagger[t] | a[i]) = k$$

entonces obtenemos una función con decaimiento exponencial para la distribución de probabilidad de  $B$ , dado  $A$  en el instante  $i$ :

$$P(b[t] | a[i]) = \begin{cases} k \cdot (1 - k)^{t-i} & \text{si } t \geq i \\ 0 & \text{si } t < i \end{cases}$$

## 5.4. Modelos canónicos y tiempo

Si consideramos una familia de nodos con  $n$  padres y dividimos el rango temporal de interés en  $i$  instantes o intervalos, en el caso general es necesario especificar  $i \cdot (i + 1)^n$  probabilidades condicionales independientes para completar la TPC asociada al nodo hijo. Si suponemos la existencia de invariancia temporal, el número anterior se reduce a  $i \cdot (i + 1)^n - (i - 1)^{n+1}$  parámetros independientes. En aplicaciones del mundo real se hace complicado disponer de una base de datos o de un experto humano que nos permitan construir tales tablas, debido al alto número de parámetros requerido, incluso en el caso de invariancia temporal. Por esta razón, sería conveniente realizar una adaptación de los modelos canónicos tradicionales para su aplicación en dominios temporales. En estos modelos, el conjunto de probabilidades condicionales requeridas varía linealmente con el número de padres.

### 5.4.1. Puerta O probabilista temporal

En general, nos estamos ocupando de dominios que pueden ser modelados asociando variables aleatorias a eventos. En el caso estático, donde no es necesario introducir explícitamente el tiempo, la puerta O probabilista modela apropiadamente el tipo de interacciones en las cuales, por una parte, la presencia de una

causa es suficiente para producir el efecto y, por otra parte, ese mecanismo causal es independiente de los mecanismos del resto de las causas. Para procesos temporales debemos tener en cuenta cuestiones adicionales, tal como se muestra a continuación.

Consideremos una red con  $n$  causas  $X_1, \dots, X_n$  y un efecto  $Y$ . Los rangos temporales de estos nodos son respectivamente  $\{0, \dots, t_{X_1}\}, \dots, \{0, \dots, t_{X_n}\}$  y  $\{0, \dots, t_Y\}$ . Cada uno de los parámetros  $c_i$  que aparecía en el caso estático (véase la sección 4.1.2), queda ahora dividido en los parámetros

$$c_{y[k]}^{x_i[j_i]} \equiv P(Z_i = y[k] \mid X_i = x_i[j_i])$$

con

$$j_i \in \{0, \dots, t_{X_i}, \text{nunca}\}, k \in \{0, \dots, t_Y, \text{nunca}\}$$

lo cual permite establecer diferentes retardos entre causa y efecto. El tipo de relación entre  $X_i$  y  $Z_i$  ya fue descrito en la sección 5.3.

Estamos interesados en calcular la probabilidad de  $Y$  en cualquier instante, dada evidencia sobre sus causas, tal como se indica en la figura 5.2, donde  $n = 2$ ,  $X_1 = x_1[i_1]$  y  $X_2 = x_2[i_2]$ .

$P(y[t] \mid x_1[i_1], x_2[i_2])$	$c_{y[\text{nunca}]}^{x_1[i_1]}$	$c_{y[n_Y]}^{x_1[i_1]}$	...	$c_{y[1]}^{x_1[i_1]}$	$c_{y[0]}^{x_1[i_1]}$
$c_{y[\text{nunca}]}^{x_2[i_2]}$	$y[\text{nunca}]$	$y[n_Y]$	...	$y[1]$	$y[0]$
$c_{y[n_Y]}^{x_2[i_2]}$	$y[n_Y]$	$y[n_Y]$	...	$y[1]$	$y[0]$
$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$	$\vdots$
$c_{y[1]}^{x_2[i_2]}$	$y[1]$	$y[1]$	...	$y[1]$	$y[0]$
$c_{y[0]}^{x_2[i_2]}$	$y[0]$	$y[0]$	...	$y[0]$	$y[0]$

Figura 5.2: Esquema gráfico del cálculo de la TPC asociada a una puerta O probabilista temporal con dos causas.

El razonamiento general seguido en la figura 5.2 establece que si  $X_1$  causa que  $Y$  sea cierto en  $t_1$ , mientras que  $X_2$  causa que  $Y$  sea cierto en  $t_2$ , entonces  $Y$  se convertiría en cierto en  $\min(t_1, t_2)$ , debido a que cada evento puede tener lugar sólo una vez. El razonamiento anterior coincide con el aplicado en una puerta MIN

probabilista. Por tanto, la *puerta O probabilista temporal* representa el caso en que el efecto está presente tan pronto como una cualquiera de sus causas provoque que esté presente.

Según la figura 5.2, una puerta MAX probabilista se transforma en una puerta O probabilista temporal asociando grados de intensidad creciente con índices temporales decrecientes. (Obsérvese que el valor “ausente” lo asociamos con el valor temporal “nunca”.) Por tanto, una puerta O probabilista temporal puede ser modelada por medio de una puerta MAX probabilista ordenando los valores temporales del futuro al pasado.

Resulta interesante estudiar el caso en que cada relación entre  $X_i$  y  $Z_i$  se caracteriza por una probabilidad con decaimiento exponencial para  $Z_i$ , dada  $X_i$  en un cierto instante o intervalo:

$$P(z_i[t] | x_i[t_i]) = \begin{cases} k_i \cdot (1 - k_i)^{t-t_i} & \text{si } t \geq t_i \\ 0 & \text{si } t < t_i \end{cases}$$

La figura 5.3, donde hemos supuesto que  $X_1$  ocurre antes que  $X_2$  ( $i_1 < i_2$ ), es el resultado de transformar la figura 5.2 para este caso particular.

$P(y[t]   x_1[i_1], x_2[i_2])$	...	$k_1(1-k_1)^{i_2-i_1+1}$	$k_1(1-k_1)^{i_2-i_1}$	...	$k_1(1-k_1)$	$k_1$	...	0	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
$k_2(1-k_2)$	...	$y[i_2+1]$	$y[i_2]$	...	$y[i_1+1]$	$y[i_1]$	...	$y[1]$	$y[0]$
$k_2$	...	$y[i_2]$	$y[i_2]$	...	$y[i_1+1]$	$y[i_1]$	...	$y[1]$	$y[0]$
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
0	...	$y[i_1+1]$	$y[i_1+1]$	...	$y[i_1+1]$	$y[i_1]$	...	$y[1]$	$y[0]$
0	...	$y[i_1]$	$y[i_1]$	...	$y[i_1]$	$y[i_1]$	...	$y[1]$	$y[0]$
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
0	...	$y[1]$	$y[1]$	...	$y[1]$	$y[1]$	...	$y[1]$	$y[0]$
0	...	$y[0]$	$y[0]$	...	$y[0]$	$y[0]$	...	$y[0]$	$y[0]$

Figura 5.3: Esquema gráfico del cálculo de la TPC asociada a una puerta O probabilista temporal con dos causas y probabilidades condicionales con decaimiento exponencial.

A partir de la figura 5.3,

$$P(y[t] | x_1[i_1], x_2[i_2]) = \begin{cases} 0 & \text{si } 0 \leq t < i_1 \\ k_1 \cdot (1 - k_1)^{t-i_1} & \text{si } i_1 \leq t < i_2 \\ k_O \cdot (1 - k_1)^{t-i_1} (1 - k_2)^{t-i_2} & \text{si } i_2 \leq t < \infty \end{cases} \quad (5.4)$$

con

$$k_O = 1 - (1 - k_1) \cdot (1 - k_2)$$

**Demostración:** Para  $0 \leq t < i_1$ ,  $Y$  no puede ser producida ni por  $X_1$  ni por  $X_2$ . Por tanto,  $P(y[t] | x_1[i_1], x_2[i_2]) = 0$ .

Para  $i_1 \leq t < i_2$ ,  $Y$  solamente puede ser causada por  $X_1$ . Esto corresponde al caso presentado en la sección 5.3. De cualquier modo, a partir de la figura 5.3 tenemos

$$\begin{aligned} P(y[t] | x_1[i_1], x_2[i_2]) &= k_1(1 - k_1)^{t-i_1} \sum_{t'=0}^{\infty} k_2(1 - k_2)^{t'} \\ &= k_1(1 - k_1)^{t-i_1} k_2 \frac{1}{1 - (1 - k_2)} \\ &= k_1(1 - k_1)^{t-i_1} \end{aligned}$$

Para  $i_2 \leq t < \infty$ , existen dos posibles causas de  $Y$ :  $X_1$  y  $X_2$ . A partir de la figura 5.3,

$$\begin{aligned} P(y[t] | x_1[i_1], x_2[i_2]) &= k_1(1 - k_1)^{t-i_1} k_2(1 - k_2)^{t-i_2} + \\ &+ k_1(1 - k_1)^{t-i_1} \sum_{t'=t-i_2+1}^{\infty} k_2(1 - k_2)^{t'} + \\ &+ k_2(1 - k_2)^{t-i_2} \sum_{t'=t-i_1+1}^{\infty} k_1(1 - k_1)^{t'} \\ &= k_1(1 - k_1)^{t-i_1} k_2(1 - k_2)^{t-i_2} + \\ &+ k_1(1 - k_1)^{t-i_1} \left( 1 - \sum_{t'=0}^{t-i_2} k_2(1 - k_2)^{t'} \right) + \\ &+ k_2(1 - k_2)^{t-i_2} \left( 1 - \sum_{t'=0}^{t-i_1} k_1(1 - k_1)^{t'} \right) \\ &= k_1(1 - k_1)^{t-i_1} k_2(1 - k_2)^{t-i_2} + \\ &+ k_1(1 - k_1)^{t-i_1} (1 - k_2)^{t-i_2+1} + \\ &+ k_2(1 - k_2)^{t-i_2} (1 - k_1)^{t-i_1+1} \\ &= k_O(1 - k_1)^{t-i_1} (1 - k_2)^{t-i_2} \end{aligned}$$

■

Cada factor  $(1 - k_j)^{t-i_j}$  de la ecuación 5.4 representa la probabilidad de que  $Y$  no haya sido producido por  $X_j$  antes de  $t$ . La constante  $k_O$  expresa la probabilidad de que  $Y$  ocurra en  $t$  si no ha ocurrido antes de  $t$ . Nótese que para  $i_1 > i_2$ , la ecuación 5.4 sigue siendo válida sin más que intercambiar en ella los subíndices “1” y “2”. Cuando  $i_1 = i_2 = i$ ,  $P(y[t] | x_1[i], x_2[i]) = k_O \cdot \{1 - [1 - (1 - k_1)(1 - k_2)]\}^{t-i}$ , lo cual es como si tuviéramos sólo una causa con una constante de decaimiento  $k_O = 1 - (1 - k_1)(1 - k_2)$ .

### 5.4.2. Puerta Y probabilista temporal

La *puerta Y probabilista temporal* representa el caso en que el efecto está presente tan pronto como todas y cada una de sus condiciones hayan permitido que esté presente, tal como se ilustra en la figura 5.4 para una familia con dos condiciones. En este tipo de interacción, si  $X_1$  permite que  $Y$  sea cierto en  $t_1$  y, por otro lado,  $X_2$  lo permite en  $t_2$ , consideramos que  $Y$  se convierte en verdadero en  $\max(t_1, t_2)$ . Este tipo de razonamiento coincide con el aplicado en una puerta MAX probabilista.

$P(y[t]   x_1[i_1], x_2[i_2])$	$h_{y[nunca]}^{x_1[i_1]}$	$h_{y[n_Y]}^{x_1[i_1]}$	...	$h_{y[1]}^{x_1[i_1]}$	$h_{y[0]}^{x_1[i_1]}$
$h_{y[nunca]}^{x_2[i_2]}$	$y[nunca]$	$y[nunca]$	...	$y[nunca]$	$y[nunca]$
$h_{y[n_Y]}^{x_2[i_2]}$	$y[nunca]$	$y[n_Y]$	...	$y[n_Y]$	$y[n_Y]$
$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$	$\vdots$
$h_{y[1]}^{x_2[i_2]}$	$y[nunca]$	$y[n_Y]$	...	$y[1]$	$y[1]$
$h_{y[0]}^{x_2[i_2]}$	$y[nunca]$	$y[n_Y]$	...	$y[1]$	$y[0]$

Figura 5.4: Esquema gráfico del cálculo de la TPC asociada a una puerta Y probabilista temporal con dos condiciones.

Según la figura 5.4, una puerta MIN probabilista conduce a una puerta Y probabilista temporal asociando grados de intensidad crecientes a índices temporales decrecientes. Por tanto, una puerta Y probabilista temporal puede ser modelada por medio de una puerta MIN probabilista ordenando los valores temporales del futuro al pasado.

En las aplicaciones de modelos canónicos, las interacciones de tipo disyuntivo (puerta O) aparecen con más frecuencia que las conjuntivas (puerta Y). Esto es así debido a que generalmente estamos interesados en modelar la evolución de los fallos o anomalías de un sistema, bien en el pasado (diagnóstico) o en el futuro (predicción). En este tipo de dominios, la interacción disyuntiva está directamente relacionada con la noción intuitiva de causalidad: para que aparezca una anomalía, es suficiente la presencia de una de sus posibles causas. En cambio, en otros dominios estamos más interesados en la evolución de un sistema desde un estado de funcionamiento defectuoso hasta otro de normalidad. En este caso, los nodos evento representan procesos de recuperación que interactúan conjuntivamente. Por ejemplo, en un accidente de tráfico tras el cual una persona resulta con heridas múltiples, podríamos modelar el proceso de recuperación de las heridas como se muestra en la figura 5.5.

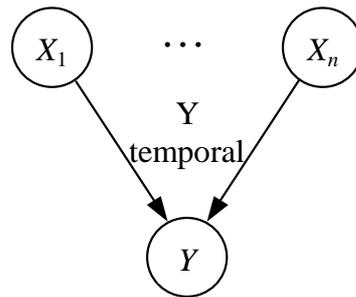


Figura 5.5: Red que modela el proceso de recuperación completa de las heridas producidas en un accidente.

Cada variable  $X_i$  representa el evento “el paciente comienza a ser tratado de la herida o lesión  $i$ ”. La variable  $Y$  representa “recuperación completa”. Todas estas variables interactúan a través de una puerta Y probabilista temporal puesto que cada  $X_i$  es una condición para  $Y$ . Por supuesto, si las  $X_i$ 's no fueran independientes entre sí, el modelo debería contener enlaces entre ellas o enlaces desde un antepasado común de las mismas.

El rango temporal de interés es  $\{0, \dots, t_m\}$ , donde  $t = 0$  es el instante en que el accidente tuvo lugar y  $t_m$  es un punto temporal arbitrario. Introducimos para cada condición  $X_i$  una variable auxiliar  $Z_i$  que representa “recuperación de la le-

sión  $i$ ". Los parámetros necesarios para completar el modelo son las probabilidades condicionales:

$$h_{y[k]}^{x_i[j_i]} \equiv P(Z_i = y[k] \mid X_i = x_i[j_i])$$

y las probabilidades a priori:

$$P(x_i[j_i])$$

con

$$j_i, k \in \{0, \dots, t_m\} \quad \text{e} \quad i \in \{1, \dots, n\} \quad (n: \text{número de condiciones})$$

Las probabilidades condicionales dan idea de las duraciones más probables de los tratamientos que se aplican a cada tipo de lesión, mientras que las probabilidades a priori indican en qué momento se empiezan a aplicar los diferentes tratamientos después del accidente. (Ciertos tratamientos se pueden aplicar justo después del accidente, otros únicamente se pueden aplicar en un hospital, etc.) El evento "recuperación completa" será cierto tan pronto como se haya producido la recuperación de la última lesión que está siendo tratada. Este tipo de razonamiento es el que se ilustra en la figura 5.4.

### 5.4.3. Puertas probabilistas temporales con residuo

Según las hipótesis introducidas por Díez y Druzdzel [48] para modelos residuales, las causas no explícitas de un nodo  $Y$  pueden ser agrupadas y representadas por medio de un vector de parámetros. Si el rango temporal de  $Y$  es  $\{0, \dots, t_Y\}$ , únicamente tenemos que especificar los parámetros

$$c_{y[i]}^* \quad \text{con} \quad i \in \{0, \dots, t_Y\}$$

Por tanto, una *puerta O probabilista temporal con residuo* puede ser modelada por medio de una puerta MIN probabilista con residuo o bien por medio de una puerta MAX probabilista con residuo. En este último caso, los índices temporales deben ser ordenados del futuro al pasado.

Las condiciones no explícitas de un modelo conjuntivo pueden ser representadas a través de un vector de parámetros

$$h_{y[i]}^* \quad \text{con} \quad i \in \{0, \dots, t_Y\}$$

Una *puerta Y probabilista temporal con residuo* puede ser modelada por medio de una puerta MAX probabilista con residuo o bien por medio de una puerta MIN probabilista con residuo. En este último caso, los índices temporales deben ser ordenados del futuro al pasado.

## 5.5. Comparación con RBDs aplicadas a procesos irreversibles

Considérese la red que aparece en la figura 5.6, donde las probabilidades a priori del nodo sin padres y las probabilidades condicionales del resto de nodos se especifican directamente.

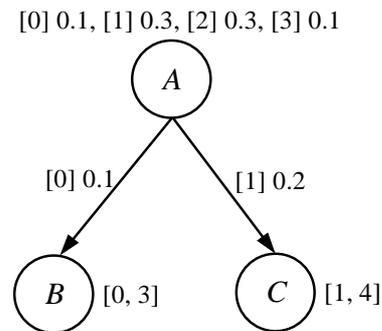


Figura 5.6: Red con un padre y dos hijos.

En el método de REPTDs, el grafo de la red no cambia. La red de eventos se completaría del siguiente modo:

- Nodos:  $A$ ,  $B$  y  $C$ .
- Valores de los nodos:  $A = \{a[0], a[1], a[2], a[3], a[nunca]\}$ ,  $B = \{b[0], b[1], b[2], b[3], b[nunca]\}$  y  $C = \{c[1], c[2], c[3], c[4], c[nunca]\}$
- Probabilidades a priori del nodo sin padres:  $P(a[0]) = 0.1$ ,  $P(a[1]) = 0.3$ ,  $P(a[2]) = 0.3$ ,  $P(a[3]) = 0.1$  y  $P(a[nunca]) = 0.2$ .
- Las TPCs, construidas a partir de los retardos especificados, aparecen en las tablas 5.3 y 5.4.

$B \setminus A$	$a[0]$	$a[1]$	$a[2]$	$a[3]$	$a[nunca]$
$b[0]$	0.1	0	0	0	0
$b[1]$	0	0.1	0	0	0
$b[2]$	0	0	0.1	0	0
$b[3]$	0	0	0	0.1	0
$b[nunca]$	0.9	0.9	0.9	0.9	1

Tabla 5.3: TPC del arco  $A \rightarrow B$ .

$C \setminus A$	$a[0]$	$a[1]$	$a[2]$	$a[3]$	$a[nunca]$
$c[1]$	0.2	0	0	0	0
$c[2]$	0	0.2	0	0	0
$c[3]$	0	0	0.2	0	0
$c[4]$	0	0	0	0.2	0
$c[nunca]$	0.8	0.8	0.8	0.8	1

Tabla 5.4: TPC del arco  $A \rightarrow C$ .

La forma de tratar la información temporal mediante RBDs es diferente en relación a nuestro enfoque. La propuesta de Kanazawa [72] para representar eventos irreversibles por medio de RBDs consiste en asociar un nodo binario a la posible ocurrencia de un evento en un punto temporal. Los *nodos memoria* (véase la sección 4.3.1 de [72]) impiden que cada tipo de evento pueda tener lugar en dos puntos temporales diferentes. Un nodo memoria es cierto cuando su evento asociado es cierto o cuando ese tipo de evento ocurrió ya en el pasado (véase la figura 5.7). La figura 5.7 muestra la transformación de la red de la figura 5.6 en una RBD, que está formada por:

- Nodos:  $A_0, A_1, A_2, A_3, B_0, B_1, B_2, B_3, C_1, C_2, C_3$  y  $C_4$ . Además, para cada evento  $N_i$  existe un nodo memoria  $M(N_i)$  que es verdadero si  $N$  ha tenido lugar en el instante  $i$  o previamente.
- Valores de cada nodo:  $\{\text{verdadero}, \text{falso}\}$
- Probabilidades a priori de los nodos sin padre:  $P(A_0 = \text{verdadero}) = 0.1$  y  $P(A_0 = \text{falso}) = 0.9$ .
- TPCs: En la tabla 5.5 aparecen las TPCs de la red de la figura 5.7.

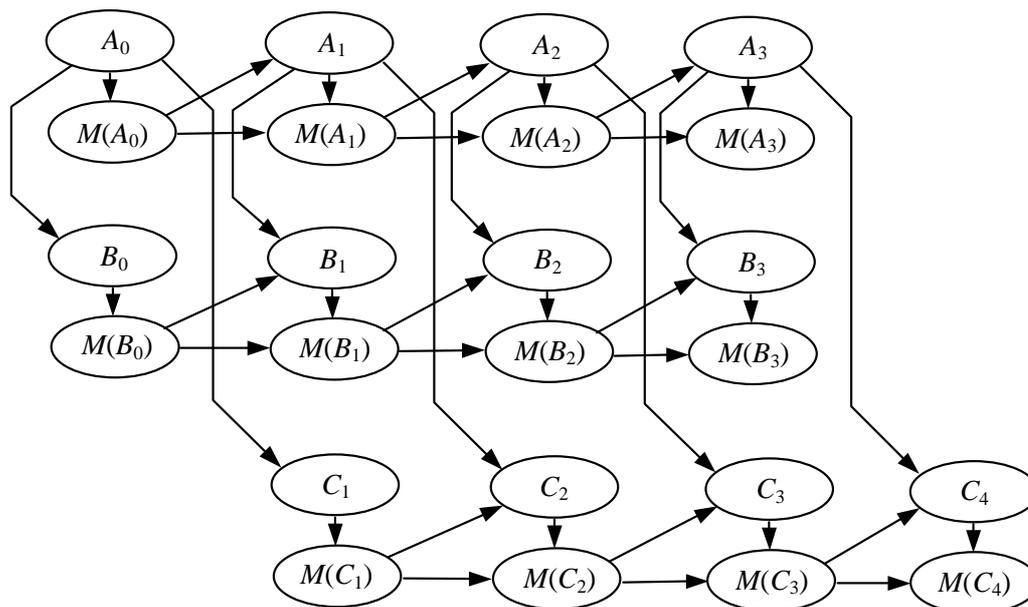


Figura 5.7: RBD con nodos memoria, obtenida a partir de la red de la figura 5.6.

$A_i \setminus M(A_{i-1})$	<i>verdadero</i>	<i>falso</i>	$A_2 \setminus M(A_1)$	<i>verdadero</i>	<i>falso</i>
<i>verdadero</i>	0	$P(a^\dagger[i])$	<i>verdadero</i>	0	$\frac{0.3}{1-0.1-0.3}$
<i>falso</i>	1	$1 - P(a^\dagger[i])$	<i>falso</i>	1	1/2

$\setminus M(X_{i-1})$	<i>verdadero</i>		<i>falso</i>	
$M(X_i) \setminus X_i$	<i>verdadero</i>	<i>falso</i>	<i>verdadero</i>	<i>falso</i>
<i>verdadero</i>	1	1	1	0
<i>falso</i>	0	0	0	1

$\setminus M(B_{i-1})$	<i>verdadero</i>		<i>falso</i>	
$B_i \setminus A_i$	<i>verdadero</i>	<i>falso</i>	<i>verdadero</i>	<i>falso</i>
<i>verdadero</i>	0	0	0.1	0
<i>falso</i>	1	1	0.9	1

$\setminus M(C_{i-1})$	<i>verdadero</i>		<i>falso</i>	
$C_i \setminus A_{i-1}$	<i>verdadero</i>	<i>falso</i>	<i>verdadero</i>	<i>falso</i>
<i>verdadero</i>	0	0	0.2	0
<i>falso</i>	1	1	0.8	1

Tabla 5.5: TPCs de la RBD asociada al ejemplo.

A pesar de que, dada cierta evidencia, ambos tipos de redes generan idénticas probabilidades a posteriori, la red de la figura 5.7 es mucho más compleja. En general, el formalismo de RBDs conduce a redes de alta complejidad estructural. En el caso de procesos irreversibles, dicha complejidad queda fuertemente reducida adoptando el método presentado en esta memoria. Por tanto, si se discretiza el tiempo, los dominios caracterizados por la presencia de procesos irreversibles se modelan más fácilmente por medio de una REPTD. Por el contrario, cuando un mismo proceso puede producirse repetidas veces, las RBDs constituyen el método más apropiado.

Por último, una ventaja de las REPTDs sobre las RBDs consiste en que las primeras no quedan restringidas a procesos markovianos. Nótese que en una RBD los arcos conectan generalmente nodos pertenecientes a la misma red estática o a redes estáticas consecutivas.

## 5.6. Relevancia temporal en REPTDs

Hasta ahora hemos representado en cada nodo todos los instantes pertenecientes a un determinado rango temporal. Generalmente no estaremos interesados en conocer las probabilidades a posteriori asociadas a todos y cada uno de dichos instantes, sino únicamente aquellas probabilidades asociadas a ciertos “instantes de interés”. En el formalismo de RBDs, un concepto similar aparece en [74]: Kjærulff introduce la noción de “ventana temporal dinámica” combinando varias redes estáticas consecutivas. Mover la ventana hacia delante implica dos procesos: expandir el modelo actual hacia el futuro en  $k$  nuevas redes estáticas y reducir el modelo actual desde el pasado en el mismo número de redes estáticas.

En una REPTD, cada hallazgo (ocurrencia de un evento en un determinado instante) genera un conjunto de instantes de interés en el resto de nodos, es decir, para cada evento de la red ciertos puntos temporales se hacen más relevantes. A lo largo de la presente sección, únicamente consideraremos interacciones de tipo disyuntivo entre nodos (puerta O), retardos limitados en el tiempo para cada arco y presencia de evidencia únicamente en un nodo de la red. La figura 5.8 muestra una red a partir de la cual hemos definido los instantes de interés (entre llaves), dados tres casos de hallazgo diferentes (encerrados en un cuadro).

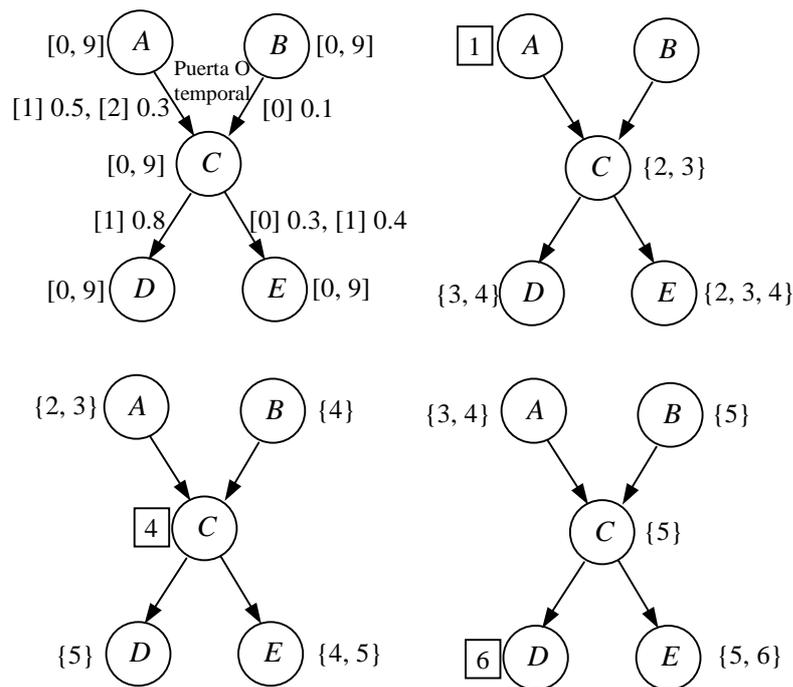


Figura 5.8: Propagación de instantes de interés en un poliárbol con interacciones disyuntivas y retardos limitados en el tiempo.

La propagación de instantes de interés en una red con estructura de árbol es un proceso inmediato. En este tipo de redes habrá instantes de interés en cualquier nodo de la red, dada cierta evidencia.

En un poliárbol existe sólo propagación hacia los nodos descendientes del nodo evidencia, hacia los antecesores de dicho nodo y, finalmente, hacia los descendientes de sus antecesores; el resto de nodos no se ven influidos por la presencia del nodo evidencia. Esto es una consecuencia de la condición de Markov, que por definición se satisface en una red bayesiana.

En una red con bucles, la propagación de instantes de interés se lleva a cabo mediante el siguiente algoritmo:

Partiendo del nodo evidencia, explorar mediante una búsqueda en profundidad el grafo formado por sus antecesores. Llamaremos al proceso anterior “exploración ascendente”, ya que sólo se tienen en cuenta los arcos entrantes a cada nodo. Para cada nodo visitado (el nodo evidencia es el primer nodo visitado), realizar las siguientes operaciones:

1. Desde el nodo visitado, propagar sus *nuevos* instantes de interés hacia todos sus descendientes. Esto se puede llevar a cabo por medio de una exploración en profundidad siguiendo los arcos salientes de cada nodo. A este proceso lo denominamos “exploración descendente”. La exploración descendente deberá omitir aquellos arcos que lleven a un nodo que pertenezca al camino activo actual de la exploración ascendente.
2. Propagar desde el nodo visitado sus *nuevos* instantes de interés hacia el siguiente de sus padres, el cual es ahora incluido en el conjunto de nodos que forman el camino activo de la exploración ascendente. Este nodo padre pasa a ser el nuevo nodo visitado. Volver al paso 1.

La figura 5.9 ilustra el desarrollo en una red concreta del algoritmo descrito. El camino activo de la exploración ascendente aparece marcado en negrita, así como los nuevos instantes de interés generados en cada nodo.

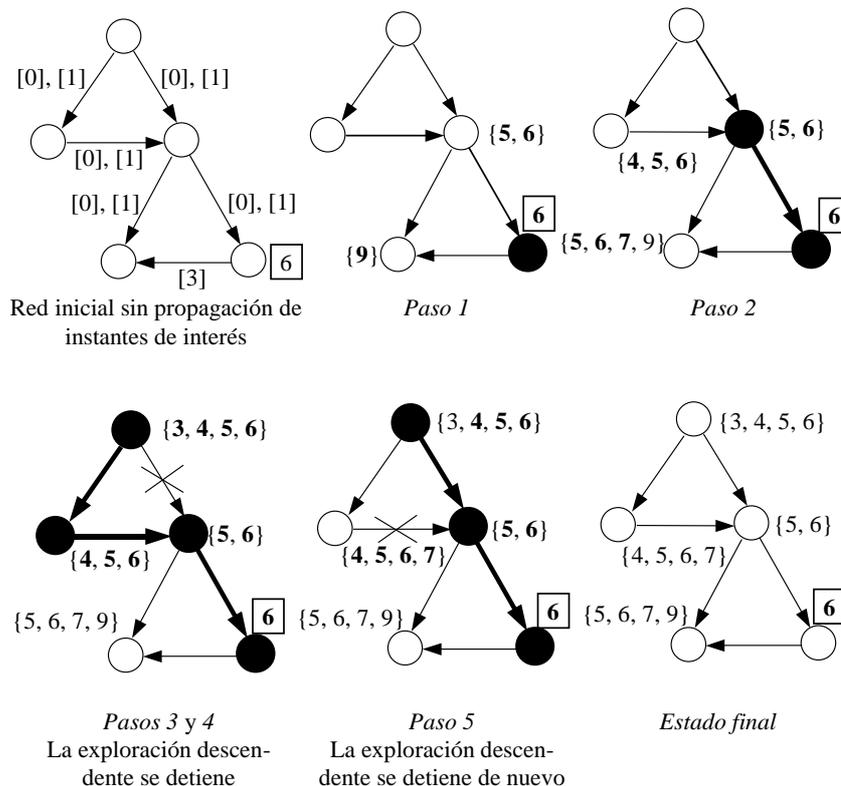


Figura 5.9: Propagación de instantes de interés a través de una red con bucles.

Obviamente, el número de valores que puede tomar cada variable decrecería como consecuencia de hacer explícitos únicamente los instantes de interés. Si, por ejemplo, una variable  $V$  se define en el rango  $\{0, \dots, t_V\}$  y estuviéramos interesados en hacer explícitos exclusivamente los puntos temporales  $t$ ,  $t + 1$  y  $t + 2$  —todos ellos pertenecientes a  $\{0, \dots, t_V\}$ —, los valores de  $V$  serían:  $v[0, t - 1]$ ,  $v[t]$ ,  $v[t + 1]$ ,  $v[t + 2]$ ,  $v[t + 3, t_V]$  y  $v[nunca]$ . Ahora,  $v[0, t - 1]$  es verdadero si el evento  $V$  ocurre en cualquier instante o intervalo entre 0 y  $t - 1$ . Del mismo modo,  $v[t + 3, t_V]$  es verdadero cuando  $V$  tiene lugar en cualquier instante o intervalo entre  $t + 3$  y  $t_V$ . Por tanto, el número total de valores ha decrecido de  $t_V + 2$  a solamente 6. Dicha reducción en el número de valores en cada variable conllevaría la aparición de TPCs de menor tamaño. En definitiva, el hacer explícitos únicamente los instantes de interés ayudaría a reducir la complejidad de redes en las que se consideran rangos temporales largos o unidades de tiempo pequeñas.

Considérese el arco de la figura 5.10, el cual podría estar incluido en una red más amplia. Su TPC asociada aparece en la tabla 5.6.

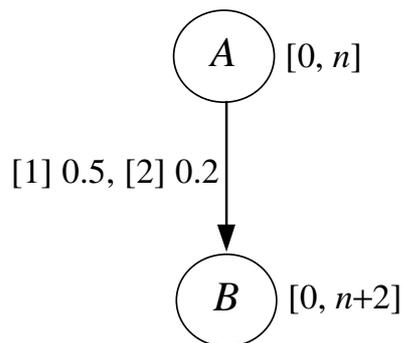


Figura 5.10: Arco con retardos.

Supongamos que una vez que los instantes de interés han sido propagados en la red, deseamos considerar explícitamente sólo  $t_B = 6$  y  $t_B = 11$ . Entonces, los nuevos valores de las variables  $A$  y  $B$ , y la TPC asociada al enlace son los que muestra la tabla 5.7.

Tal como se puede deducir a partir de la tabla 5.7, la agrupación de varios puntos temporales conduce a una probabilidad condicional que se calcula sumando las probabilidades condicionales asociadas a cada uno de los retardos representados en el enlace.

$B \setminus A$	$a[0]$	$a[1]$	$\dots$	$a[n]$	$a[nunca]$
$b[0]$	0	0	$\dots$	0	0
$b[1]$	0.5	0	$\dots$	0	0
$b[2]$	0.2	0.5	$\dots$	0	0
$b[3]$	0	0.2	$\dots$	0	0
$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$	$\vdots$
$b[n+1]$	0	0	$\dots$	0.5	0
$b[n+2]$	0	0	$\dots$	0.2	0
$b[nunca]$	0.3	0.3	$\dots$	0.3	1

Tabla 5.6: TPC de un arco con retardos pero sin instantes de interés.

$B \setminus A$	$a[0,3]$	$a[4]$	$a[5]$	$a[6,8]$	$a[9]$	$a[10]$	$a[11,n]$	$a[nunca]$
$b[0,5]$	0.7	0.5	0	0	0	0	0	0
$b[6]$	0	0.2	0.5	0	0	0	0	0
$b[7,10]$	0	0	0.2	0.7	0.5	0	0	0
$b[11]$	0	0	0	0	0.2	0.5	0	0
$b[12,n+2]$	0	0	0	0	0	0.2	0.7	0
$b[nunca]$	0.3	0.3	0.3	0.3	0.3	0.3	0.3	1

Tabla 5.7: TPC de un arco con retardos e instantes de interés.

Las probabilidades a posteriori de los valores asociados a instantes de interés permanecen sin cambios en relación al caso en que todos los valores del rango temporal son representados explícitamente. Por otra parte, alcanzaríamos idénticos resultados bien calculando la probabilidad a posteriori de un nuevo valor que agrupa un conjunto de puntos temporales, bien sumando las probabilidades a posteriori obtenidas por separado para cada punto temporal de dicho conjunto.

## 5.7. Ejemplo de aplicación

Deseamos modelar la evolución de los atascos de tráfico que se producen en las afueras de una ciudad después del acaecimiento de un evento (accidente de tráfico, catástrofe natural, etc.) que obliga a cortar el tráfico indefinidamente. Estamos interesados en el período de tiempo previo al comienzo de la jornada laboral, ya que entonces existe un flujo mayor de vehículos.

En la figura 5.11, los nodos  $C_1$  y  $C_2$  representan dos puntos de destino diferentes para trabajadores que diariamente acceden a sus puestos de trabajo.  $C_1$  y  $C_2$  están situados en el centro de la ciudad. Cada nodo  $P_1$ ,  $P_2$  o  $P_3$  podría ser un cruce de carreteras, una ciudad dormitorio..., es decir, no se trata de puntos de destino.

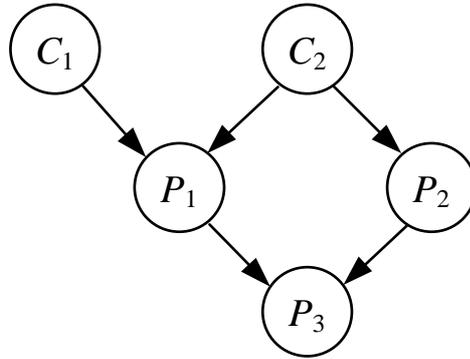


Figura 5.11: Afueras de una ciudad.

A continuación se ilustra la aplicación del enfoque de REPTDs al dominio discreto. Cada nodo representa el evento “aparición de atasco” en el lugar asociado al nodo. Las flechas indican la dirección de propagación del atasco de tráfico, que es la contraria a la del tráfico. El rango temporal de interés comienza a las 8:10 de la mañana y finaliza a las 9:00 de la mañana. Dividimos dicho rango en intervalos de diez minutos. Cada familia de nodos de la red interactúa según el modelo de puerta O probabilista temporal; por ejemplo, puede aparecer un atasco en  $P_3$  si ha aparecido previamente en  $P_1$  o  $P_2$ .  $P_3 = p_3[8:30]$  significa que se ha creado un atasco en  $P_3$  entre las 8:21 y 8:30 de la mañana. Suponemos que el evento inicial causante de los problemas impide el restablecimiento normal del tráfico en el rango temporal de interés (de 8:10 de la mañana a 9:00 de la mañana).

Las tablas 5.8 y 5.9 muestran las probabilidades a priori de  $C_1$  y  $C_2$ , respectivamente. Por ejemplo,  $P(c_1[8:40])$  es la probabilidad de que ocurra un evento que cause un atasco indefinido en  $C_1$  entre las 8:31 y 8:40 de la mañana. Las probabilidades presentadas a lo largo de la presente sección son arbitrarias. De cualquier modo, la propia ciudad constituiría la mejor base de datos de la cual obtener estos parámetros.

Nótese que la probabilidad de atasco crece a medida que el tiempo avanza. Esto

$c_1[8:20]$	$c_1[8:30]$	$c_1[8:40]$	$c_1[8:50]$	$c_1[9:00]$	$c_1[nunca]$
0.0001	0.0005	0.001	0.0025	0.003	0.9929

Tabla 5.8: Probabilidades a priori de  $C_1$ .

$c_2[8:20]$	$c_2[8:30]$	$c_2[8:40]$	$c_2[8:50]$	$c_2[9:00]$	$c_2[nunca]$
0.0002	0.0005	0.0015	0.003	0.0035	0.9913

Tabla 5.9: Probabilidades a priori de  $C_2$ .

es así debido a que la jornada laboral tiene su comienzo generalmente a las 9:00 de la mañana y la probabilidad de accidente depende del flujo de vehículos. Las TPCs de la red pueden ser construidas a partir de los parámetros de las tablas 5.10, 5.11 y 5.12.

Los parámetros de la red indican que a medida que nos acercamos geográficamente al centro de la ciudad o a medida que el reloj avanza hacia las 9:00 de la mañana, la probabilidad de propagación de atasco entre nodos vecinos es mayor, así como la probabilidad de que dicha propagación tenga lugar en un período de tiempo menor. Nótese que las distancias entre  $P_1$  y  $C_2$ , y entre  $P_2$  y  $C_2$ , son mucho mayores que en el resto de arcos. Existen causas no explícitas en el modelo; por ejemplo, un accidente podría causar un atasco en un nodo periférico mientras la situación en el centro de la ciudad es normal.

La tabla 5.13 muestra las probabilidades a posteriori para  $P_2 = p_2[9:00]$ . A partir de dicha tabla,  $c_2[8:20]$  y  $c_2[8:30]$  constituyen las explicaciones más probables de la evidencia observada. Si también supiéramos que  $P_1 = p_1[8:30]$  entonces  $C_2$  no explicaría la evidencia sobre  $P_1$  y, en consecuencia, se produciría un incremento en la probabilidad de  $c_1[8:20]$  y  $c_1[8:30]$  (véase la tabla 5.14).

## 5.8. Cálculo eficiente de la probabilidad en puertas MAX probabilistas

La mayoría de entornos para la creación de redes bayesianas que permiten introducir puertas O/MAX probabilistas, expanden las TPCs asociadas a este tipo de familias antes de realizar inferencia. Este método posee el inconveniente de no

$P_1$	$c_1[8:20]$	$c_1[8:30]$	$c_1[8:40]$	$c_1[8:50]$	$c_1[9:00]$	residuo
$p_1[8:20]$	0.15	0	0	0	0	0.00005
$p_1[8:30]$	0.15	0.15	0	0	0	0.0002
$p_1[8:40]$	0.15	0.15	0.2	0	0	0.0005
$p_1[8:50]$	0.2	0.2	0.2	0.25	0	0.0011
$p_1[9:00]$	0.25	0.3	0.3	0.35	0.5	0.0014
$p_1[nunca]$	$1 - 0.9$	$1 - 0.8$	$1 - 0.7$	$1 - 0.6$	$1 - 0.5$	0.99675
	$c_2[8:20]$	$c_2[8:30]$	$c_2[8:40]$	$c_2[8:50]$	$c_2[9:00]$	
$p_1[8:20]$	0	0	0	0	0	
$p_1[8:30]$	0	0	0	0	0	
$p_1[8:40]$	0	0	0	0	0	
$p_1[8:50]$	0.1	0	0	0	0	
$p_1[9:00]$	0.13	0.14	0	0	0	
$p_1[nunca]$	$1 - 0.23$	$1 - 0.14$	1	1	1	

Tabla 5.10: Parámetros asociados a  $P_1$ .

$P_2 \setminus C_2$	$c_2[8:20]$	$c_2[8:30]$	$c_2[8:40]$	$c_2[8:50]$	$c_2[9:00]$	residuo
$p_2[8:20]$	0	0	0	0	0	0.00004
$p_2[8:30]$	0	0	0	0	0	0.0003
$p_2[8:40]$	0	0	0	0	0	0.0004
$p_2[8:50]$	0.13	0	0	0	0	0.0012
$p_2[9:00]$	0.15	0.15	0	0	0	0.0015
$p_2[nunca]$	$1 - 0.28$	$1 - 0.15$	1	1	1	0.99656

Tabla 5.11: Parámetros asociados a  $P_2$ .

$P_3$	$p_1[8:20]$	$p_1[8:30]$	$p_1[8:40]$	$p_1[8:50]$	$p_1[9:00]$	residuo
$p_3[8:20]$	0.12	0	0	0	0	0.00002
$p_3[8:30]$	0.12	0.14	0	0	0	0.0001
$p_3[8:40]$	0.14	0.15	0.15	0	0	0.0003
$p_3[8:50]$	0.18	0.19	0.2	0.2	0	0.0006
$p_3[9:00]$	0.2	0.22	0.25	0.3	0.4	0.0008
$p_3[nunca]$	$1 - 0.76$	$1 - 0.7$	$1 - 0.6$	$1 - 0.5$	$1 - 0.4$	0.99818
	$p_2[8:20]$	$p_2[8:30]$	$p_2[8:40]$	$p_2[8:50]$	$p_2[9:00]$	
$p_3[8:20]$	0.1	0	0	0	0	
$p_3[8:30]$	0.12	0.12	0	0	0	
$p_3[8:40]$	0.15	0.15	0.15	0	0	
$p_3[8:50]$	0.18	0.2	0.2	0.19	0	
$p_3[9:00]$	0.2	0.24	0.26	0.29	0.39	
$p_3[nunca]$	$1 - 0.75$	$1 - 0.71$	$1 - 0.61$	$1 - 0.48$	$1 - 0.39$	

Tabla 5.12: Parámetros asociados a  $P_3$ .

	8:20	8:30	8:40	8:50	9:00	<i>nunca</i>
$C_1$	0.0001	0.0005	0.001	0.0025	0.003	0.9929
$C_2$	<b>0.01879</b>	<b>0.04704</b>	0.0014	0.0028	0.00327	0.92667
$P_1$	0.00006	0.00028	0.00078	0.00391	0.01319	0.98174
$P_3$	0.00002	0.00014	0.00047	0.0016	0.3937	0.60404

Tabla 5.13: Probabilidades a posteriori para  $P_2 = p_2[9:00]$ .

	8:20	8:30	8:40	8:50	9:00	<i>nunca</i>
$C_1$	<b>0.05177</b>	<b>0.25892</b>	0.00068	0.00172	0.00206	0.68481
$C_2$	0.01879	0.04704	0.0014	0.0028	0.00327	0.92667
$P_3$	0.00002	0.14008	0.15019	0.19023	0.3368	0.18266

Tabla 5.14: Probabilidades a posteriori para  $P_1 = p_1[8:30]$  y  $P_2 = p_2[9:00]$ .

aprovechar las ventajas que ofrecen los modelos O/MAX. De hecho, en este método la complejidad del cómputo de probabilidades en una familia con  $N$  padres es  $O(n_Y \cdot n_X^N)$ , suponiendo que el nodo hijo puede tomar  $n_Y$  valores y cada nodo padre,  $n_X$  valores. Se han propuesto diferentes técnicas para evitar esta complejidad exponencial. Las más significativas son el algoritmo de Díez [45], cuya complejidad es  $O(n_Y \cdot n_X \cdot N)$  para una puerta MAX probabilista que forme parte de un poliárbol, y la *factorización multiplicativa* de Takikawa y D'Ambrosio [86, 126], cuya complejidad es  $O(\max(2^{n_Y}, n_Y \cdot n_X \cdot N))$ . La técnica de Takikawa y D'Ambrosio posee la ventaja de permitir órdenes de eliminación eficientes para el algoritmo de eliminación de variables, y triangulaciones eficientes cuando es combinado con algoritmos de agrupamiento. En la próxima sección describimos un nuevo algoritmo [47], propuesto por el Prof. Javier Díez, que reúne las ventajas de las dos técnicas mencionadas, es decir, la eficiencia del primer algoritmo de Díez y la flexibilidad de la factorización multiplicativa. Nuestra participación en este estudio ha sido el análisis empírico de la complejidad temporal del algoritmo.

### 5.8.1. Un nuevo algoritmo para la puerta MAX probabilista

En una puerta MAX probabilista (véase la sección 4.1.2), el grado alcanzado por el nodo hijo  $Y$  es el máximo de los grados producidos independientemente por cada

uno de sus nodos padre  $X_i$ :

$$P(Y \leq y \mid \mathbf{x}) = \prod_i P(Y \leq y \mid X_i = x_i, X_j = 0_{[\forall j, j \neq i]}) \quad (5.5)$$

donde  $\mathbf{x} = (x_1, \dots, x_n)$  representa una determinada configuración de los padres de  $Y$ .

Definiendo los parámetros:

$$C_y^{x_i} = P(Y \leq y \mid X_i = x_i, X_j = 0_{[\forall j, j \neq i]}) = \sum_{y'=0}^y C_{y'}^{x_i}$$

la ecuación 5.5 se puede escribir de la forma:

$$P(Y \leq y \mid x_1, \dots, x_n) = \prod_i C_y^{x_i} \quad (5.6)$$

La TPC se obtiene teniendo en cuenta que

$$P(y \mid \mathbf{x}) = \begin{cases} P(Y \leq 0 \mid \mathbf{x}) & \text{si } y = 0 \\ P(Y \leq y \mid \mathbf{x}) - P(Y \leq y - 1 \mid \mathbf{x}) & \text{si } y > 0 \end{cases} \quad (5.7)$$

El nuevo algoritmo parte del hecho de que la ecuación 5.7 puede ser expresada como un producto de matrices. Por ejemplo, cuando  $n_Y = 3$ ,

$$\begin{pmatrix} P(Y = 0 \mid \mathbf{x}) \\ P(Y = 1 \mid \mathbf{x}) \\ P(Y = 2 \mid \mathbf{x}) \end{pmatrix} = \begin{pmatrix} 1 & 0 & 0 \\ -1 & 1 & 0 \\ 0 & -1 & 1 \end{pmatrix} \cdot \begin{pmatrix} P(Y \leq 0 \mid \mathbf{x}) \\ P(Y \leq 1 \mid \mathbf{x}) \\ P(Y \leq 2 \mid \mathbf{x}) \end{pmatrix}$$

En general,

$$P(y \mid \mathbf{x}) = \sum_{y'} \Delta_Y(y, y') \cdot P(Y \leq y' \mid \mathbf{x})$$

donde  $\Delta_Y$  es una matriz  $n_Y \times n_Y$  dada por

$$\Delta_Y(y, y') = \begin{cases} 1 & \text{si } y' = y \\ -1 & \text{si } y' = y - 1 \\ 0 & \text{en otro caso} \end{cases}$$

Teniendo en cuenta la ecuación 5.6,

$$P(y \mid \mathbf{x}) = \sum_{y'} \Delta_Y(y, y') \cdot \prod_i C_{y'}^{x_i} \quad (5.8)$$

Esta factorización de  $P(y \mid \mathbf{x})$  constituye el fundamento del nuevo algoritmo.

A continuación mostramos cómo integrar la factorización dada por la ecuación 5.8 con los algoritmos generales para la propagación exacta de la evidencia en redes bayesianas.

### Integración con eliminación de variables

En la factorización de la probabilidad conjunta, cada TPC correspondiente a una familia MAX puede ser reemplazada por su equivalente según la ecuación 5.8. Seguidamente, la eliminación de variables puede proseguir de la manera usual como si  $Y'$  fuera una variable más.

Podría ocurrir que el procedimiento que determina el orden de eliminación decidiera sumar sobre  $Y'$  antes que sobre  $Y$  y sus padres, lo cual equivaldría a expandir la TPC entera para esta familia. En este caso, el nuevo algoritmo no proporcionaría ninguna ventaja desde el punto de vista computacional. Sin embargo, en general la eliminación de la variable  $Y'$  puede ser pospuesta hasta que otras variables hayan sido eliminadas, con lo cual se consigue un ahorro de espacio y tiempo, tal como se muestra en el siguiente ejemplo.

Dada la red de la figura 4.1, supongamos que estamos interesados en la probabilidad a posteriori de  $A$  dada la evidencia  $\{H = h_k\}$ . El cálculo se puede llevar a cabo de la siguiente forma si existiera una puerta MAX probabilista en el nodo  $G$ :

$$\begin{aligned}
 P(a, h_k) &= \sum_b \sum_d \sum_f \sum_g \sum_{g'} P(a) \cdot P(b | a) \cdot P(d | a) \\
 &\quad \cdot P(f) \cdot \Delta_G(g, g') \cdot C_{g'}^b \cdot C_{g'}^d \cdot C_{g'}^f \cdot P(h_k | g) \\
 &= P(a) \cdot \sum_{g'} \left[ \left( \sum_b P(b | a) \cdot C_{g'}^b \right) \cdot \left( \sum_d P(d | a) \cdot C_{g'}^d \right) \right. \\
 &\quad \left. \cdot \left( \sum_f P(f) \cdot C_{g'}^f \right) \cdot \left( \sum_g \Delta_G(g, g') \cdot P(h_k | g) \right) \right]
 \end{aligned}$$

Es fácil comprobar que esta ecuación es mucho más eficiente que la ecuación 4.3 debido a la factorización dada por la ecuación 5.8.

### Integración con algoritmos de agrupamiento

Hemos comprobado que la integración del nuevo algoritmo con el método de eliminación de variables es inmediata. A continuación mostramos cómo integrarlo con algoritmos de agrupamiento. El proceso es el siguiente:

**Algoritmo 1** *Construcción del árbol de unión:*

1. *Construir un grafo (no dirigido) auxiliar del siguiente modo:*
  - a) *Crear un grafo con el mismo conjunto de nodos que la red bayesiana pero sin enlaces.*
  - b) *Para cada nodo  $V$ :*
    - i. *Si  $V$  es el hijo de una familia MAX, insertar en el grafo auxiliar un nuevo nodo  $V'$  con  $\text{dom}(V') = \text{dom}(V)$ , insertar un enlace  $V'-V$  y a continuación un enlace  $U_i-V'$  para cada arco  $U_i \rightarrow V$  de la red bayesiana (es decir, para cada padre  $U_i$  de  $V$ ).*
    - ii. *En caso contrario, insertar un enlace  $U_i-V$  para cada arco  $U_i \rightarrow V$  de la red y casar (enlazar) los padres entre sí.*
2. *Triangular el grafo auxiliar.*
3. *Organizar los cliques del grafo triangulado en un árbol de unión.*
4. *Asignar los potenciales a los cliques.*

Por ejemplo, el grafo auxiliar de la red de la figura 4.1 aparece en la figura 5.12. Existen dos formas posibles de triangular este grafo: la adición de un enlace  $B-D$  o la adición de un enlace  $A-G'$ . La última conduce al árbol de cliques mostrado en la figura 5.13.

Es preciso realizar los siguientes comentarios sobre este algoritmo:

- El paso 1 del algoritmo garantiza que siempre sea posible asignar los potenciales de la red al árbol de unión. Dada una TPC,  $P(y | \mathbf{x})$ , existirá al menos un clique que contenga todos los nodos de la familia (paso 1(b)ii del algoritmo). Si un nodo  $Y$  interactúa con sus padres mediante una puerta MAX, existirá al menos un clique que contenga tanto a  $Y$  como a  $Y'$  (paso 1(b)i), al que se le podrá asignar el potencial  $\Delta_Y(y, y')$ . Por la misma razón, es posible asignar cada  $C_y^{x_i}$  a un clique que contenga tanto a  $X_i$  como a  $Y'$ . En el caso de una puerta MAX con residuo, el potencial  $C_y^*$  podrá ser asignado a cualquier clique que contenga a  $Y$ .

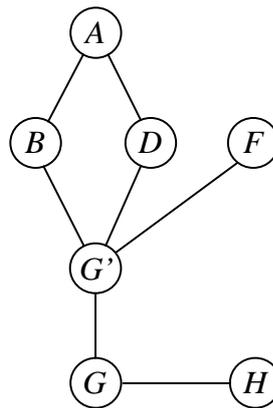


Figura 5.12: Grafo auxiliar de la red bayesiana de la figura 4.1.

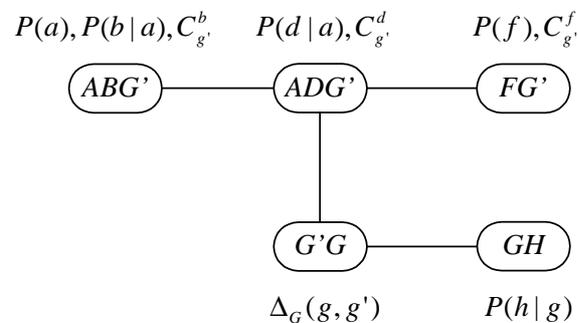


Figura 5.13: Un posible árbol de unión para el grafo de la figura 5.12. Muestra los potenciales asociados a cada clique.

- El grafo auxiliar no es necesariamente un grafo moralizado debido a que es posible que los padres pertenecientes a una puerta MAX no estén casados. Esto puede resultar sorprendente para quien está familiarizado con los algoritmos de agrupamiento, pero el papel principal del árbol de unión es servir de estructura para el almacenamiento y combinación de los potenciales. Por tanto, si la TPC de una familia puede ser descompuesta en un conjunto de potenciales, no es necesario tener un cúmulo que incluya a todos los nodos de la familia. Basta con que, para cada potencial, exista un cúmulo que contenga todas sus variables.
- Los pasos 2, 3 y 4 del algoritmo coinciden con los de otros algoritmos de agrupamiento.

### 5.8.2. Estudio experimental

Dentro del trabajo desarrollado en la presente tesis doctoral, hemos realizado una serie de pruebas (consúltese [49]) para medir la eficiencia computacional del nuevo algoritmo en redes generadas aleatoriamente. En el primer tipo de pruebas creamos 25 variables binarias y establecimos arcos entre ellas eligiendo aleatoriamente 25 pares de nodos. Para cada par  $(X_i, X_j)$  generado, trazamos el arco  $X_i \rightarrow X_j$  si  $i < j$  o el arco  $X_j \rightarrow X_i$  en caso contrario; de esta manera evitábamos la aparición de ciclos. Asignamos a cada familia una puerta MAX probabilista (de hecho se trataba de puertas O probabilistas ya que todas las variables eran binarias) y propagamos la evidencia mediante el método de Shenoy-Shafer [123], primero con las TPCs generales y después con probabilidades condicionales factorizadas. Evidentemente, el árbol de unión era diferente en cada uno de estos dos casos. Repetimos las pruebas con un total de 50 redes generadas aleatoriamente y a continuación reiniciamos todo el proceso anterior con redes de 30, 35, ... y 80 arcos. La figura 5.14 representa el tiempo promedio empleado en el cálculo de las probabilidades a priori en función del número de nodos.

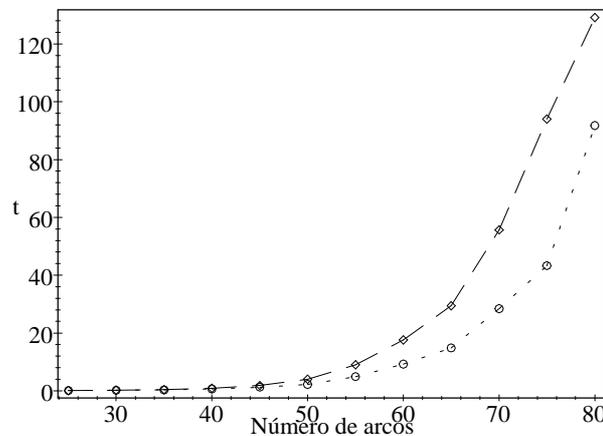


Figura 5.14: Tiempo promedio (en segundos) para 50 redes de 25 variables binarias, en función del número de arcos. La propagación se realiza con TPCs generales ( $\diamond$ ) y con puertas MAX factorizadas ( $\circ$ ).

Realizamos un experimento similar con 10 variables de 5 valores cada una. El número de arcos variaba en esta ocasión de 10 a 24. Nuevamente todas las familias

interactuaban mediante puertas MAX probabilistas y generamos 50 redes de forma aleatoria para cada número de arcos. Los resultados se muestran en la figura 5.15.

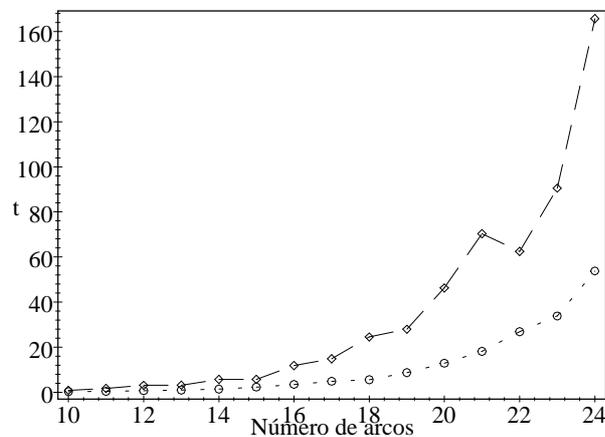


Figura 5.15: Tiempo promedio (en segundos) para 50 redes con 10 variables de 5 valores, en función del número de arcos. La propagación se realiza con TPCs generales (◇) y con puertas MAX factorizadas (○).

En los dos tipos de pruebas realizadas se observa cómo la complejidad computacional disminuye.

### 5.8.3. Otros trabajos relacionados

Tal como se ha mencionado, la complejidad del cálculo de la probabilidad en una familia con un nodo hijo  $Y$  de  $n_Y$  valores y  $N$  padres  $\{X_1, \dots, X_N\}$  que toman cada uno  $n_X$  valores, es  $O(n_Y \cdot n_X^N)$ . El primer algoritmo que aprovechó los modelos canónicos para simplificar el cálculo de probabilidades en redes bayesianas fue el método de Pearl para la puerta O probabilista [106, sección 4.3.2], cuya complejidad es  $O(N)$ . Díez [45] propuso un algoritmo similar para la puerta MAX probabilista, cuya complejidad es  $O(n_Y \cdot n_X \cdot N)$ ; sin embargo, para redes con bucles este algoritmo tiene que ser integrado con el método de condicionamiento local [46], el cual no es en general tan eficiente como los métodos de agrupamiento basados en triangulaciones óptimas o casi óptimas.

En 1999, Takikawa y D'Ambrosio propusieron un tipo de factorización multiplica-

tiva de la probabilidad condicional de una puerta MAX probabilista. La integración de este método con SPI [122] —que es básicamente un algoritmo de eliminación de variables— lleva a una complejidad de  $O(\max(2^{n_Y}, n_Y \cdot n_X \cdot N))$ , la cual mejoraba los resultados obtenidos con métodos anteriores; en particular, permite calcular cualquier probabilidad marginal de la red CPCS [136] en unos pocos segundos. Este método de *factorización multiplicativa* también puede ser integrado con algoritmos de agrupamiento mediante la introducción de  $n_Y - 1$  variables binarias intermedias en cada familia MAX de la red [86].

El algoritmo expuesto en esta sección se basa también en una factorización multiplicativa dada por la ecuación 5.8, la cual resume las ecuaciones 5.6 y 5.7. La principal diferencia reside en que, para cada familia MAX, la factorización sugerida por Takikawa y D'Ambrosio introduce  $n_Y - 1$  variables auxiliares  $\{Y'_0, \dots, Y'_{n_Y-2}\}$ , todas ellas padres de  $Y$  e hijas de  $\{X_1, \dots, X_N\}$ ; por esta razón la complejidad de su algoritmo crece exponencialmente con  $n_Y$ . Por el contrario, este nuevo algoritmo sólo introduce una variable auxiliar  $Y'$ , que conduce a una complejidad  $O(n_Y^2)$ . Esta diferencia es relevante cuando  $n_Y$  es grande, como en el caso de los modelos canónicos temporales desarrollados en la presente tesis doctoral.

## Capítulo 6

# Implementación de modelos temporales en Elvira

Un grupo de investigadores españoles pertenecientes a ocho universidades iniciaron a finales de la década de los noventa una labor conjunta para el desarrollo de un entorno que permitiera la construcción y aplicación de sistemas expertos basados en modelos gráficos probabilísticos. El proyecto Elvira (TIC97-1135-C04) sirvió de marco común para la coordinación del trabajo de los cuatro subproyectos que en un principio se formaron: Granada, Almería, País Vasco y UNED.

El nombre oficial del proyecto fue “Entorno de Desarrollo para Modelos Gráficos Probabilísticos”, aunque los participantes en el mismo decidieron darlo a conocer como “Proyecto Elvira”, inspirándose en el antiguo nombre de Granada, ciudad a cuya universidad estaban vinculados parte de los investigadores del proyecto.

El objetivo inicial del Proyecto Elvira era la construcción de un entorno<sup>1</sup> que permitiera la investigación de nuevos métodos y algoritmos de razonamiento probabilístico, además de servir de herramienta para la implementación de sistemas expertos bayesianos.

---

<sup>1</sup>El entorno Elvira es de uso libre y está disponible via Internet en la dirección <http://www.ia.uned.es/~elvira>.

## 6.1. El entorno Elvira

Algunas de las características generales que actualmente posee el entorno Elvira son las siguientes:

- Está escrito y compilado en Java, por lo que puede funcionar en diferentes plataformas y sistemas operativos.
- Utiliza un formato propio para la codificación de redes bayesianas y diagramas de influencia, y un lector (párser) que interpreta los modelos codificados.
- Dispone de una interfaz gráfica para la construcción de redes. Una de las propiedades de esta interfaz es que permite introducir modelos canónicos (puertas O, Y... probabilistas).
- Ofrece la posibilidad de hacer uso de un amplio abanico de algoritmos de razonamiento tanto de carácter exacto como aproximado. Dichos algoritmos se pueden aplicar a variables discretas o continuas.
- Está dotado de métodos de explicación de razonamiento y algoritmos para la toma de decisiones (evaluación de diagramas de influencia).
- Permite realizar fusión de redes y aprendizaje de modelos a partir de bases de datos.

En la figura 6.1 se muestra la pantalla principal de Elvira. En la barra de menú de Elvira aparecen las siguientes opciones:

- **Archivo:** Contiene una serie de apartados para la gestión de los archivos asociados a las redes creadas en el entorno. Permite crear, abrir o guardar redes, entre otras posibilidades.
- **Editar:** Se utiliza para crear nodos o enlaces que pasen a formar parte de la red, seleccionarlos, borrarlos o copiarlos.
- **Ver:** Selecciona la etiqueta visual asociada a un nodo, que puede ser bien el nombre de la variable que representa bien el título del nodo. En modo inferencia permite escoger la precisión (número de decimales) con que se muestran los resultados.

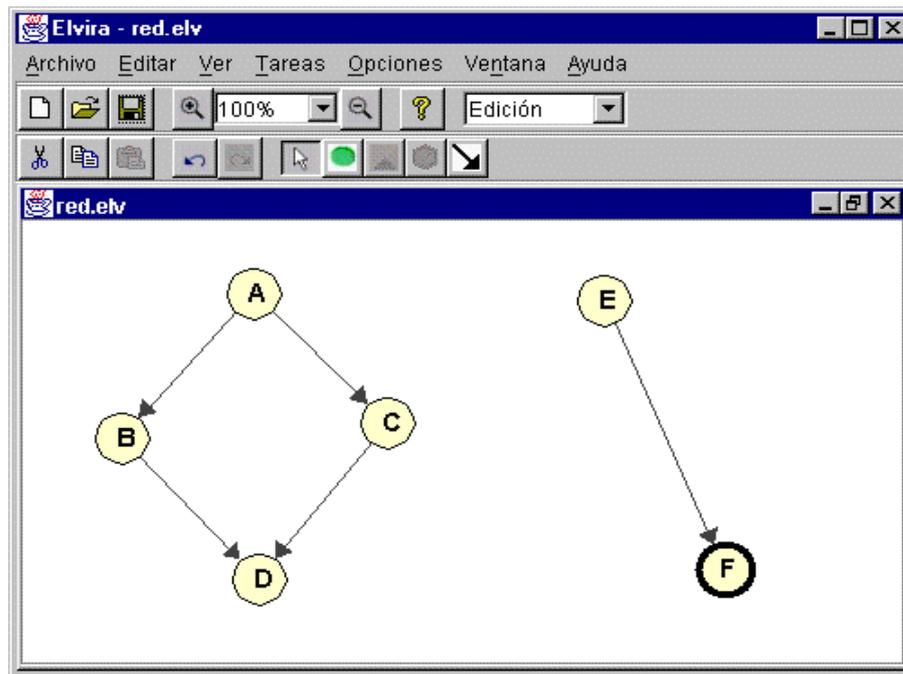


Figura 6.1: Pantalla principal del entorno Elvira.

- **Tareas:** Permite llevar a cabo operaciones como, por ejemplo, la fusión de dos redes bayesianas.
- **Opciones:** Ofrece la posibilidad de elegir entre diferentes métodos de propagación de la evidencia, entre diferentes métodos de aprendizaje, así como ajustar una serie de parámetros relacionados con la inferencia y la explicación del razonamiento en redes.
- **Ventana:** Gestiona la ordenación de las diferentes ventanas abiertas en el entorno en un momento dado.
- **Ayuda:** Permite acceder a información sobre el entorno.

En la barra de herramientas superior, existen opciones para cambiar la escala con que la red es visualizada o para cambiar el modo de operación. Existen tres modos de operación en Elvira: edición, inferencia y aprendizaje.

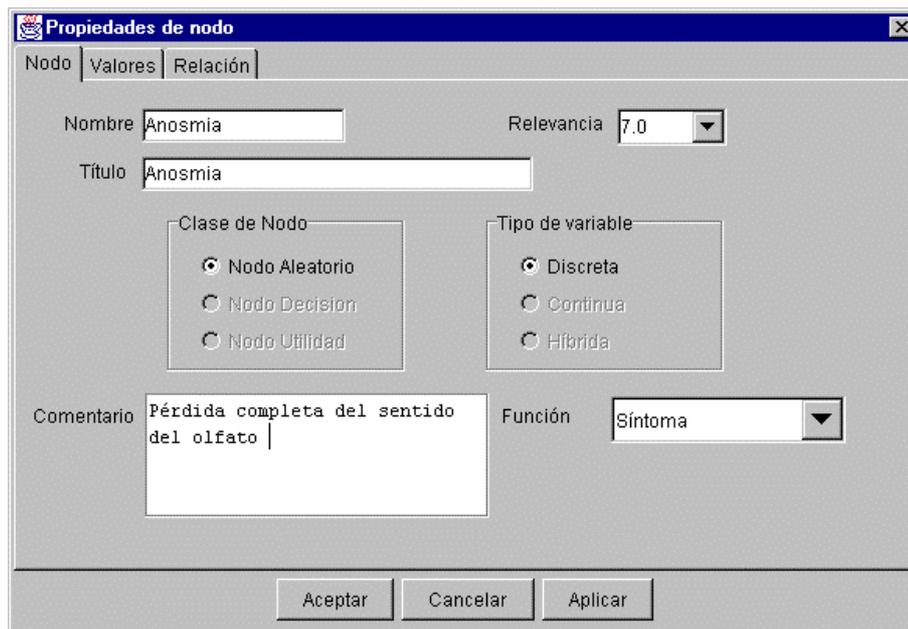


Figura 6.2: Ventana para la definición del nombre y del título de un nodo en el entorno Elvira.

### 6.1.1. Edición de redes en Elvira

El proceso de edición de una red en el entorno Elvira consta de los siguientes pasos:

1. Definición del **tipo de red** (bayesiana, diagrama de influencia...), del **tipo de variables** (discretas, continuas o ambas) y del **nombre de la red**.
2. Definición de la **estructura de la red**, es decir, de los nodos y enlaces de los que se compone. Cada nodo tiene una serie de propiedades que pueden ser visualizadas en pantalla. En la figura 6.2 aparece la ventana donde se introduce el nombre del nodo. Los valores que puede tomar la variable asociada al nodo se introducen a través de una ventana como la mostrada en la figura 6.3.
3. Introducción de los **parámetros numéricos**, es decir, la tabla de probabilidades condicionales de cada nodo. En la figura 6.4 aparece el aspecto que tendría dicha tabla para un nodo binario con dos padres también binarios.

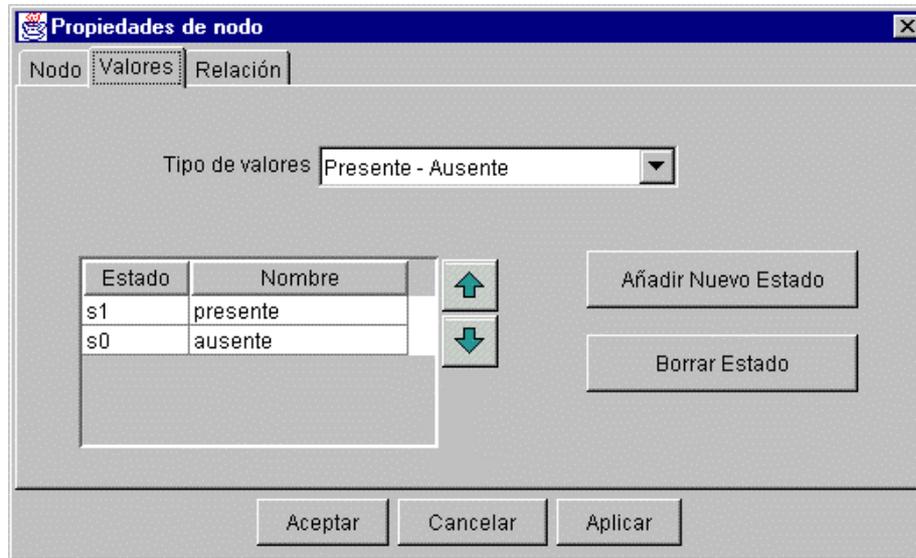


Figura 6.3: Ventana para la definición de los valores de un nodo en Elvira.

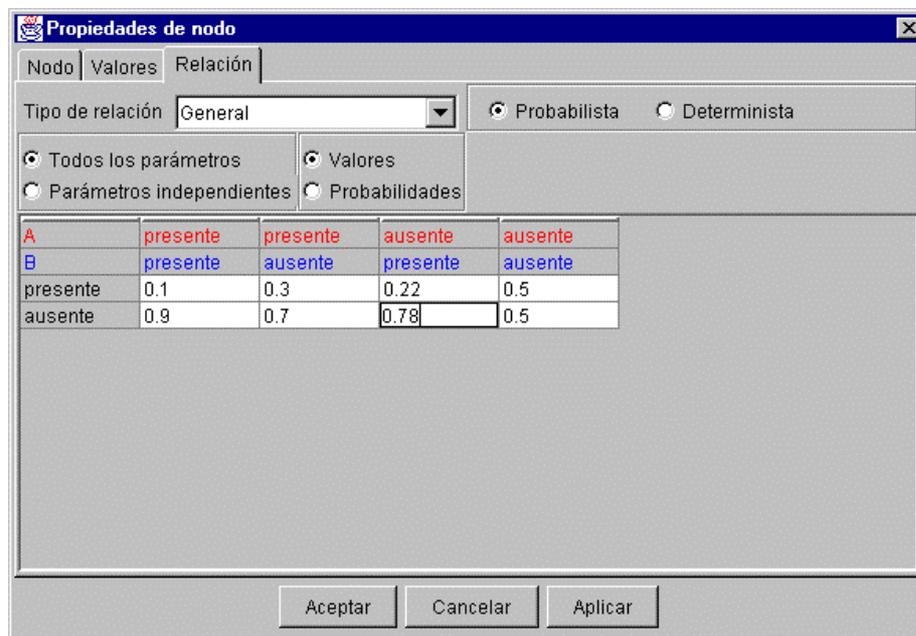


Figura 6.4: Tabla de probabilidades condicionales de un nodo en Elvira, cuyos padres son  $A$  y  $B$ .

### 6.1.2. Inferencia en Elvira

Al entrar en modo inferencia, se obtiene una pantalla con la apariencia mostrada en la figura 6.5. En dicha pantalla se puede observar la aparición de una nueva barra de herramientas inferior, que sustituye a la barra de edición y ofrece nuevas opciones relacionadas con la inferencia en la red.

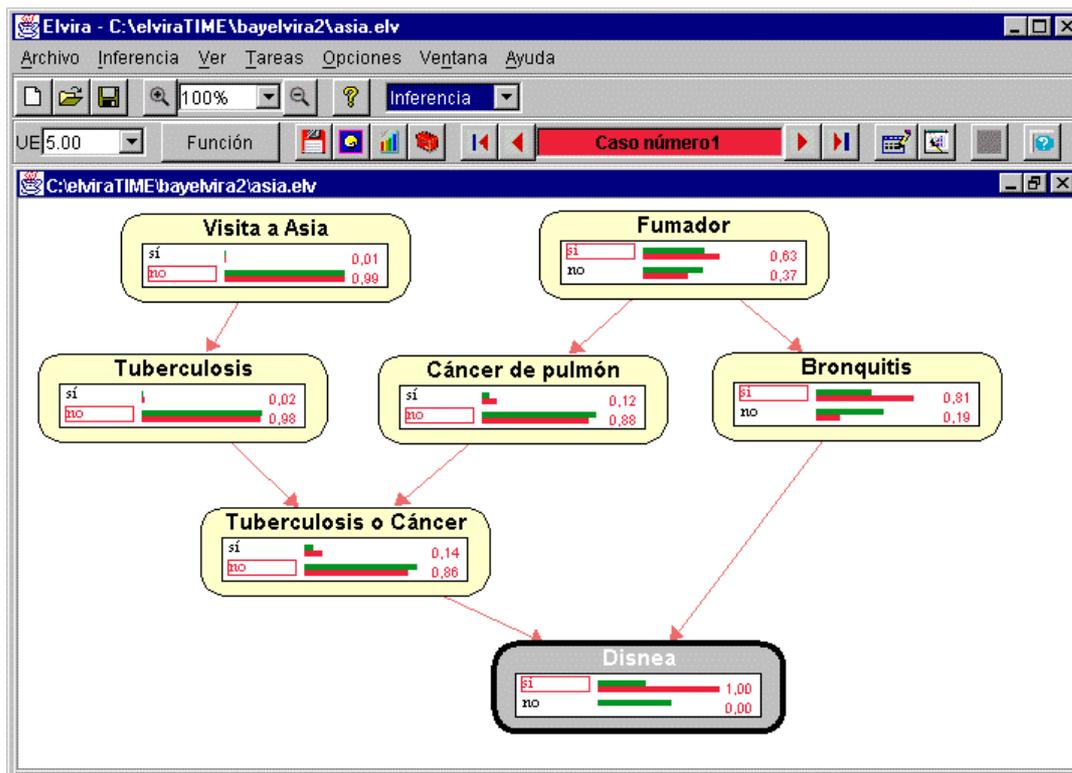


Figura 6.5: Pantalla obtenida en modo inferencia en Elvira.

El efecto más evidente al entrar en modo inferencia es la expansión de los nodos de la red y la visualización de sus probabilidades a priori mediante números y mediante barras de tamaño proporcional a los mismos. Con posterioridad, se pueden introducir sucesivamente diferentes *casos de evidencia*. Cada caso de evidencia viene definido por un conjunto de hallazgos y es visualizado con barras de un determinado color en cada nodo. Casos de evidencia diferentes son representados con colores diferentes. De esta manera, el usuario puede hacerse una idea del impacto que cada hallazgo ejerce sobre las probabilidades a posteriori del resto de las variables.

Asociado a cada nodo, existe un parámetro denominado “relevancia” que admite valores enteros entre 0 y 10, y es asignado por el experto al construir la red. Un nodo se expande en modo inferencia si su relevancia es mayor o igual que el “umbral de expansión” (véase la parte superior izquierda de la figura 6.5) introducido por el usuario. Por tanto, a través de la relevancia definida en cada nodo y del umbral de expansión seleccionado, es posible elegir qué nodos se expandirán y cuáles no en modo inferencia.

### 6.1.3. Explicación del razonamiento en Elvira

En realidad, ninguno de los entornos existentes para la edición y evaluación de redes bayesianas o diagramas de influencia es capaz de explicar al usuario los resultados de la propagación de la evidencia. En Elvira se ha intentado superar esta dificultad por medio de diferentes métodos.

La interfaz gráfica constituye uno de los métodos para la explicación del razonamiento en Elvira [76, 77, 79]. Este método consiste en trabajar con varios casos de evidencia, cuyas probabilidades a posteriori son mostradas simultáneamente en pantalla.

Los diferentes casos de evidencia presentes en un momento dado pueden ser gestionados de forma rápida y sencilla. Para ello están disponibles una serie de opciones para la creación, borrado o edición de dichos casos evidencia. Para cada caso de evidencia, en cada nodo se señala el valor más probable encerrándolo en un rectángulo.

El resto de métodos para la explicación del razonamiento en Elvira están relacionados con la posibilidad de ofrecer información específica sobre ciertos nodos o enlaces mediante explicaciones verbales o gráficas. Se puede encontrar una explicación más detallada en la tesis doctoral de la Prof<sup>a</sup> Carmen Lacave [76].

## 6.2. Creación de REPTDs en Elvira

Una de las peculiaridades de las REPTDs es el gran número de valores o estados que se suelen definir en los nodos temporales que forman parte de las mismas. Si por

regla general en una red bayesiana no temporal el número de valores de cada nodo suele estar entre dos y cuatro, y raramente supera la media docena, a lo largo de los capítulos dedicados a la descripción de aplicaciones médicas e industriales de las REPTDs mostramos ejemplos de nodos que pueden tomar por encima de la decena e incluso de la treintena de valores.

La simple definición de los valores de un nodo temporal de una REPTD resultaría una tarea ciertamente tediosa si se tuviera que realizar manualmente y valor a valor en un entorno para la creación de redes bayesianas. Téngase en cuenta que la definición de todos los valores de un nodo temporal sería un proceso secuencial en el que en cada paso se solicitaría la adición de un nuevo valor a la lista actual de valores del nodo y, además, habría que darle un nombre a dicho nuevo valor. Es cierto, por otra parte, que la comprobación de que no se repite el mismo nombre en dos valores diferentes del mismo nodo sería inmediata en el caso de eventos temporales, ya que a valores diferentes les asociaríamos números enteros diferentes.

Si el proceso de definición de los valores de un nodo temporal resultaría largo e incómodo en un entorno para la creación de redes bayesianas, dichos inconvenientes se agudizan a la hora de introducir en la red los parámetros numéricos temporales que la completan.

En el caso de un nodo temporal sin padres, sería necesario especificar un valor de probabilidad a priori para cada valor. Esto, que en una red bayesiana no temporal llevaría en general unos pocos segundos, en una REPTD requeriría mucho más tiempo. Considérese, por ejemplo, el caso de una REPTD con 10 nodos sin padres y 20 valores en cada nodo. Si suponemos que la introducción de un valor de probabilidad en el entorno dura al menos 5 segundos, el proceso completo de introducción de las probabilidades a priori de los nodos sin padres se completaría en un total de  $5 \times 20 \times 10$  segundos, algo más de 16 minutos.

En el párrafo previo hemos supuesto que el diseñador conoce de antemano todos los valores de la distribución de probabilidad que quiere introducir en un nodo sin padres. Pero podría darse el caso de que únicamente conociera el valor de una constante  $k$  ( $0 \leq k \leq 1$ ) y quisiera definir a partir de ella una distribución de probabilidad con decaimiento exponencial para el nodo sin padres. En este caso, el propio diseñador debería calcular dicha distribución, a falta de una utilidad dentro del en-

torno bayesiano que le permitiera obtenerla automáticamente. Tal como indicamos en la sección 5.2, la probabilidad a priori del valor  $i$ -ésimo de un nodo temporal  $V$  sujeto a una distribución de probabilidad con decaimiento exponencial definido por la constante  $k$  es:

$$P(v[t_i]) = k \cdot (1 - k)^{i-1} \quad i = 1, 2, \dots$$

En la figura 6.6 se muestra una distribución de probabilidad con decaimiento exponencial ( $k = 0.6$ ) para un nodo temporal  $V$  definido en un rango de 6 unidades temporales.

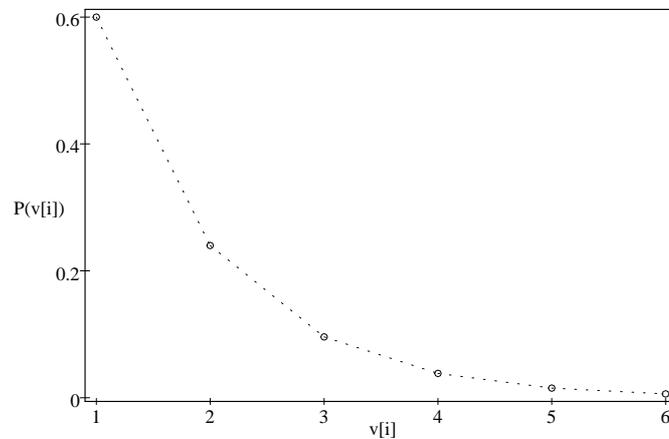


Figura 6.6: Distribución de probabilidad con decaimiento exponencial ( $k = 0.6$ ).

En el caso de redes bayesianas no temporales, el diseñador introduce los valores de la TPC asociada a una familia de nodos completando con probabilidades las casillas mostradas en una tabla cuyo número de filas coincide con el número de valores del nodo hijo y cuyo número de columnas coincide con el número de posibles configuraciones de valores en el conjunto de nodos padre. De esta manera el diseñador puede introducir las probabilidades condicionales de una familia de nodos sin más que **localizar** la casilla correspondiente en una tabla de dimensiones aceptables.

En el caso de REPTDs, ya comentamos en el capítulo 5 que la TPC de una familia de nodos temporales con varios padres contendría generalmente un número ingente de parámetros, lo cual convierte en inabordable su utilización, incluso en el caso de invariancia temporal. El hecho anterior motivó el que formalizáramos diferentes modelos canónicos temporales, de entre los cuales elegimos la puerta O

probabilista temporal como modelo base para la implementación de aplicaciones médicas e industriales (véanse los capítulos 7 y 8).

En una familia de nodos que interactúan de acuerdo a un modelo de puerta O probabilista temporal, la tabla completa de parámetros de la familia tiene un número de filas igual al de valores del nodo hijo y un número de columnas igual a la suma de valores de los nodos padre (más una columna adicional, si se tienen en cuenta los parámetros residuales). (La tabla 5.10 y la figura 6.13 muestran dos ejemplos del tipo de tabla mencionado.) Por ejemplo, en el caso de una familia de 4 padres, si cada nodo posee 20 valores, la tabla resultante estaría formada por algo más de 1.600 parámetros. Ante este hecho, cabe realizar las siguientes consideraciones:

- Tal como indicamos en el capítulo 5, aproximadamente la mitad de esos algo más de 1.600 parámetros son nulos de antemano y, por tanto, convendría que el diseñador no tuviera que introducirlos manualmente y uno a uno en el sistema.
- En el caso de invariancia temporal, únicamente habría que especificar una columna de parámetros por cada padre. El resto de columnas, análogamente a lo reseñado en la consideración anterior, deberían ser automáticamente rellenadas por el sistema y no por el diseñador.
- Suponiendo que dispusiéramos de un entorno que nos exigiera introducir tan sólo el conjunto de parámetros independientes de una familia de nodos, según lo indicado en las consideraciones anteriores, estaríamos en una situación en que deseamos introducir un pequeño conjunto de parámetros en una tabla de algo más de 1.600 casillas. Además, los parámetros independientes que queremos rellenar están distribuidos de forma más o menos uniforme a lo largo de toda la superficie de la tabla. No es deseable ni cómodo tener que localizar manualmente una casilla concreta en una tabla de aproximadamente 1.600 casillas, que obviamente no puede ser visualizada enteramente en la pantalla de un ordenador. Por tanto, un entorno para la creación de REPTDs debería ser capaz de solicitar al diseñador, de forma amigable —no mediante tablas como las utilizadas en el caso de redes bayesianas no temporales— los parámetros probabilísticos independientes necesarios.
- Todo lo comentado en la presente sección en relación a la introducción de distri-

buciones de probabilidad con decaimiento exponencial para nodos sin padres, es válido para el caso en que deseemos definir distribuciones de probabilidad condicional con decaimiento exponencial. Es decir, el sistema debería ofrecer al diseñador la posibilidad de establecer automáticamente este tipo de distribuciones en los parámetros de una familia de nodos, sin más que especificar la constante de decaimiento correspondiente.

En las secciones que siguen describiremos en detalle cómo hemos implementado en el entorno Elvira los requisitos derivados de las consideraciones anteriores.

### 6.2.1. Especificación de nodos temporales en Elvira

En el entorno Elvira, la selección de un nodo de una red bayesiana permite abrir una ventana en la que se pueden definir las propiedades del nodo (véanse las figuras 6.2, 6.3 y 6.4).

En la pestaña “Valores” (figura 6.3) se especifican los valores del nodo. En esta pestaña existe la posibilidad de seleccionar valores predeterminados: *presente/ausente*, *alto/medio/bajo* o *severo/moderado/ligero/ausente*, entre otros. También existen botones para añadir un nuevo estado o valor al conjunto de valores actuales, así como para borrar un determinado valor.

En Elvira, un nodo temporal puede ser introducido seleccionando la opción “Temporales” del conjunto de valores predeterminados que ofrece el sistema. Al realizar dicha selección, se abre una nueva ventana como la mostrada en la figura 6.7, que permite definir los límites inferior y superior del rango temporal del nodo actual. Si por ejemplo el límite inferior introducido es “1” y el superior es “4”, los valores que podría tomar el nodo serían  $\{t_1, t_2, t_3, t_4, nunca\}$ , tal como se muestra en la figura 6.8.

Desde el momento en que se define un nodo como temporal, Elvira lo reconoce como tal y así lo indica en el cuadro “Tipo de valores” en cualquier ocasión posterior en que el nodo sea seleccionado y se abra la ventana para definir sus propiedades. Por otro lado, existe la posibilidad de redefinir el rango de un nodo temporal cuando así se desee sin más que seguir el mismo procedimiento descrito para la creación de nodos temporales.



Figura 6.7: Ventana para la definición del rango temporal de un nodo evento.

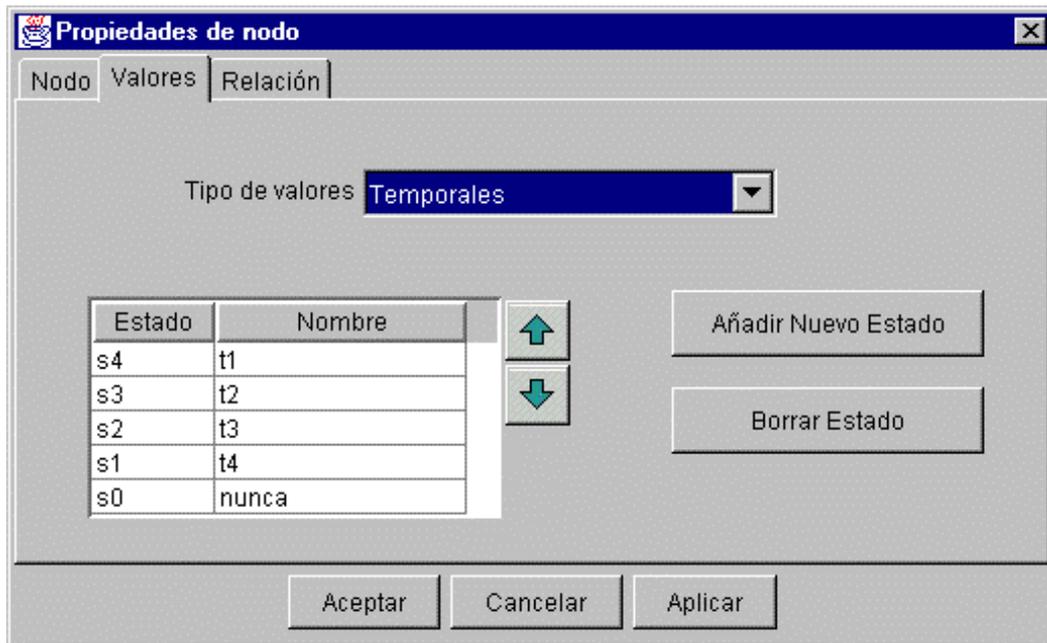


Figura 6.8: Valores temporales de un nodo evento.

Es necesario haber definido de antemano un nodo como temporal para poder hacer uso posterior de las utilidades que ofrece el sistema para la creación automática de diferentes tipos de distribuciones a priori temporales (en nodos sin padres) o de diferentes tipos de distribuciones condicionales temporales (en nodos con padres).

### 6.2.2. Especificación de los parámetros probabilísticos temporales asociados a un nodo

En la pestaña “Relación” (véase la figura 6.4) de la ventana que muestra las propiedades de un nodo, existe una lista desplegable, denominada “Tipo de relación”,

que permite seleccionar el tipo de interacción que el nodo actual tiene con sus nodos padre: puerta O probabilista, puerta MAX probabilista... Una de estas relaciones, denominada genéricamente “Relación temporal”, ofrece al diseñador la posibilidad de introducir los parámetros que el nodo temporal necesita. Al seleccionar esta opción, pueden aparecer dos tipos de diálogo: el correspondiente a un nodo temporal sin padres o el correspondiente a un nodo temporal con padres.

### Especificación de los parámetros temporales de un nodo sin padres

La figura 6.9 muestra la ventana para la definición de las probabilidades a priori de un nodo temporal sin padres en Elvira.

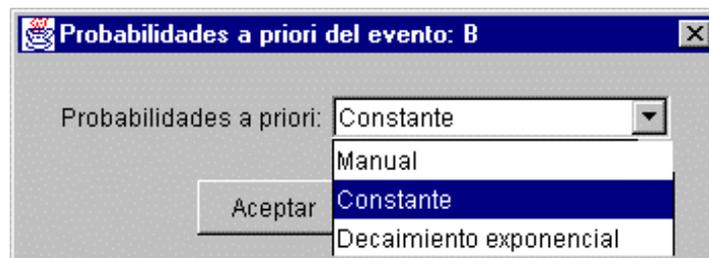


Figura 6.9: Ventana para la definición de las probabilidades a priori de un nodo temporal sin padres.

Existen tres opciones diferentes para elegir el tipo de distribución de probabilidad a priori que se va a asociar a los valores temporales del nodo:

- **Manual:** El diseñador introduce manualmente en una tabla (véase la figura 6.10) los valores de las probabilidades a priori.
- **Constante:** El diseñador introduce un valor de probabilidad (véase la figura 6.11) que definirá una distribución de probabilidad constante para el nodo que estamos considerando. Evidentemente, el sistema avisará al diseñador en caso de que el valor introducido sea demasiado grande, es decir, cuando la constante especificada haga que la suma de probabilidades de los valores del nodo supere la unidad.

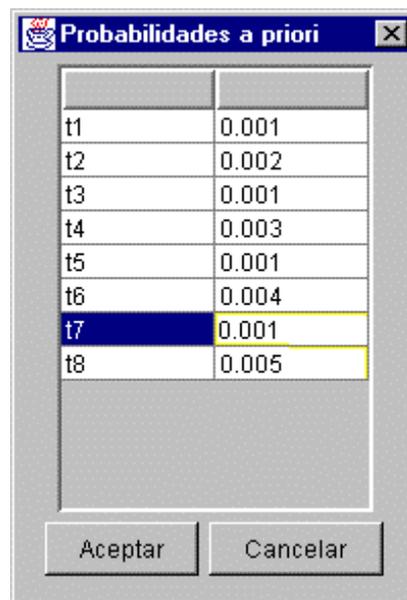


Figura 6.10: Definición manual de las probabilidades a priori de un nodo temporal.

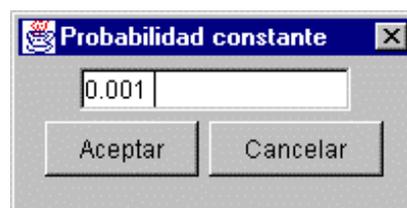


Figura 6.11: Ventana que solicita al usuario un valor de probabilidad que servirá para definir una distribución constante de probabilidad.

- **Decaimiento exponencial:** El diseñador introduce un valor de probabilidad que definirá una distribución de probabilidad con decaimiento exponencial. En este caso, al contrario que en el de una distribución constante, cualquier valor perteneciente al intervalo  $(0, 1)$  será válido.

### Especificación de los parámetros temporales de un nodo con padres

Debido a que en las aplicaciones médicas e industriales descritas en la presente memoria hacemos uso únicamente del modelo de puerta O probabilista temporal con invariancia, éste es el tipo de relación temporal que hemos implementado en

Elvira para nodos con padres. Por tanto, en nuestra implementación esta clase de relación temporal constituye la relación establecida por defecto para una familia de nodos temporales.

La figura 6.12 muestra la ventana que surge al definir los parámetros temporales de una familia de nodos evento con dos padres, denominados *A* y *B* en la figura.



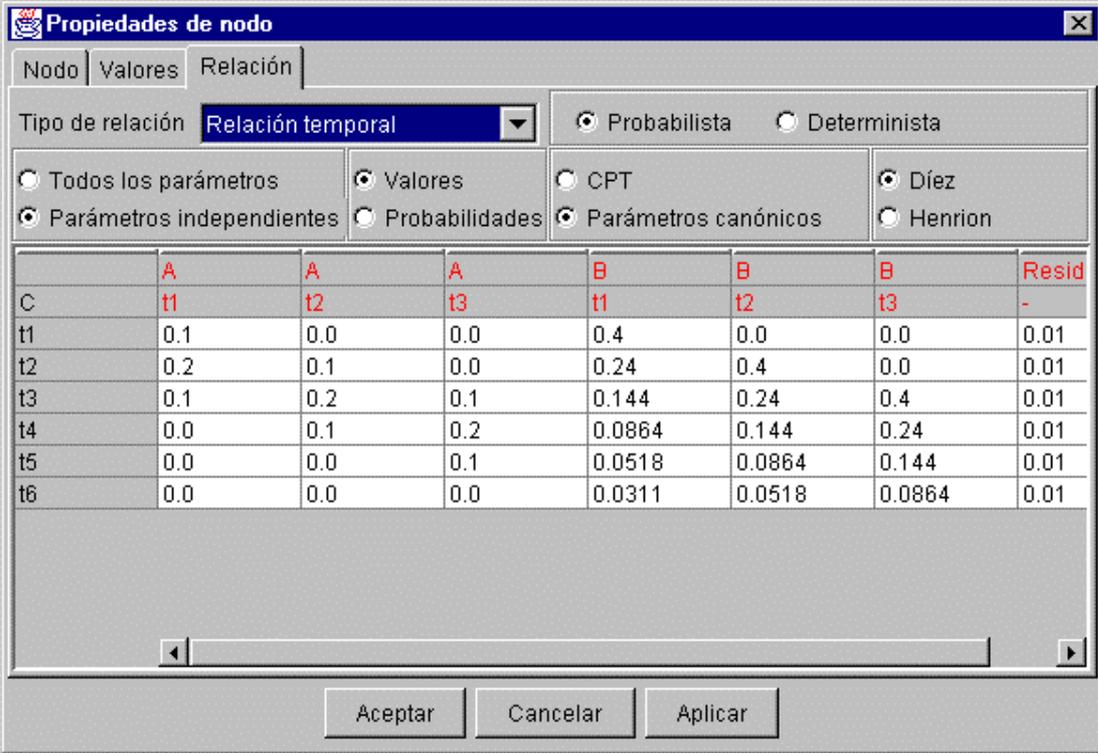
Figura 6.12: Ventana para la definición de los parámetros temporales de una familia con dos padres.

Tal como se puede observar en la figura 6.12, por una parte se puede seleccionar el padre de la familia cuyos parámetros se quiere definir y, por otra parte, se puede seleccionar el tipo de distribución con invariancia temporal que se desee para esos parámetros. Al igual que en el caso de nodos temporales sin padres, se puede elegir entre tres tipos de distribuciones diferentes: manual, constante y con decaimiento exponencial. Esta última es la que aparece seleccionada en la figura 6.12. Nótese la importancia que tiene el poder elegir una distribución constante cuando se quiere, por ejemplo, que los parámetros residuales sean nulos.

Dado un padre seleccionado y un tipo de distribución definida para el mismo, el botón “*Aplicar*” permite validar los parámetros introducidos para dicho padre. Una vez presionado el botón “*Aplicar*”, se seleccionaría otro padre diferente y se definiría a continuación un nuevo tipo de distribución para él. Obsérvese que este método facilita en gran medida la introducción de los parámetros asociados a un familia, ya que evita que el diseñador tenga que localizar casillas en una tabla de gran tamaño.

La figura 6.13 muestra la tabla resultante para una familia de nodos temporales con dos padres *A* y *B*. Nótese que hemos elegido para el nodo hijo un rango mayor

que el de los nodos padre. Los parámetros correspondientes al arco  $A \rightarrow C$  se han introducido manualmente en una tabla de una columna, mientras que los correspondientes al arco  $B \rightarrow C$  representan una distribución con decaimiento exponencial ( $k = 0.4$ ). Finalmente, hemos elegido parámetros residuales constantes e iguales a 0.01.



	A	A	A	B	B	B	Resid
C	t1	t2	t3	t1	t2	t3	-
t1	0.1	0.0	0.0	0.4	0.0	0.0	0.01
t2	0.2	0.1	0.0	0.24	0.4	0.0	0.01
t3	0.1	0.2	0.1	0.144	0.24	0.4	0.01
t4	0.0	0.1	0.2	0.0864	0.144	0.24	0.01
t5	0.0	0.0	0.1	0.0518	0.0864	0.144	0.01
t6	0.0	0.0	0.0	0.0311	0.0518	0.0864	0.01

Figura 6.13: Tabla asociada a una familia de nodos temporales que interactúan según un modelo de puerta O probabilista temporal.

En la figura 6.14 mostramos el resultado del cálculo en Elvira de las probabilidades a priori para todos los nodos temporales de la familia descrita. Hemos introducido probabilidades a priori correspondientes a una distribución con decaimiento exponencial para  $A$  ( $k = 0.6$ ) y una distribución constante para  $B$  ( $k = 0.01$ ).

Finalmente, antes de presentar la parte de aplicaciones de que consta la memoria, queremos hacer notar que el entorno Elvira, tal como lo hemos descrito en este

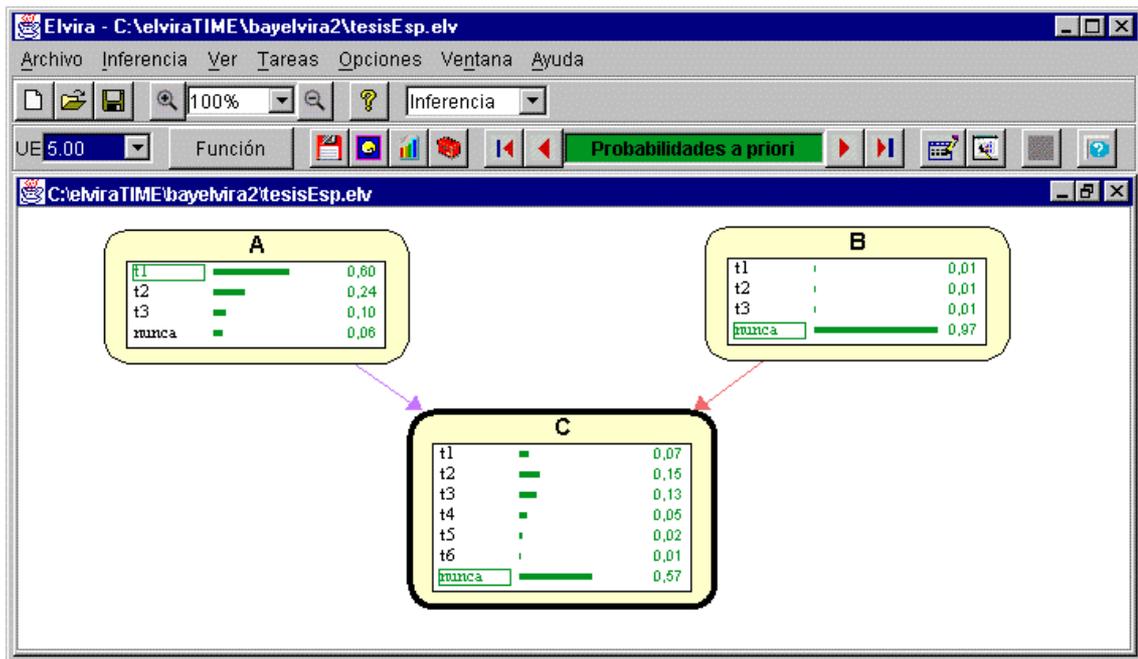


Figura 6.14: Probabilidades a priori en Elvira para una familia de tres nodos temporales.

capítulo, no es en la actualidad un programa de diseño cerrado e invariable. La evolución futura de las utilidades ofrecidas en el entorno seguirá un camino paralelo al propio rumbo que tomen los modelos gráficos probabilísticos en los próximos años.



## Parte III

# APLICACIONES



# Capítulo 7

## NasoNet, diagnóstico y pronóstico de cáncer de nasofaringe

El crecimiento de un cáncer es un proceso dinámico de carácter no determinista. En consecuencia, el diseño de un sistema para la ayuda en el diagnóstico y pronóstico de la extensión de un cáncer debe estar basado en un método que permita representar incertidumbre y tiempo. El objetivo es conocer la etapa de desarrollo alcanzada por un cáncer en el paciente, antes de elegir la terapia adecuada. El perfil de paciente en el que estamos interesados corresponde a aquellos enfermos provenientes del Servicio de Otorrinolaringología de un hospital, que son admitidos en el Servicio de Oncología Radioterápica; concretamente, nuestro trabajo se ha desarrollado en colaboración con oncólogos pertenecientes al Hospital Clínico Universitario San Carlos de Madrid.

El presente capítulo describe detalladamente las características de NasoNet, un sistema que aplica REPTDs al diagnóstico y pronóstico de cáncer de nasofaringe. Hemos empleado puertas probabilistas temporales para modelar las interacciones causales dinámicas que tienen lugar en el dominio. La metodología descrita tiene carácter general y se puede aplicar a cualquier otro tipo de cáncer.

### 7.1. Redes bayesianas para diagnóstico de cáncer

El diagnóstico y el pronóstico de la extensión de un cáncer son tareas llenas de incertidumbre. Esto es debido, por un lado, a la naturaleza no determinista de

esta enfermedad y, por otro lado, a la información incompleta, imprecisa o errónea que el oncólogo puede obtener. Por ello, las redes bayesianas resultan apropiadas para el modelado de procesos causales con incertidumbre como los que determinan la evolución de un cáncer. Algunas aplicaciones de redes bayesianas a dominios oncológicos son:

- PATHFINDER [65, 66], un sistema experto para el diagnóstico de enfermedades de los ganglios linfáticos. PATHFINDER hace uso de la llamada *red de semejanza probabilística*, que representa los posibles diagnósticos en un solo nodo. Además, se supone que el paciente padece una única enfermedad, lo cual resulta una hipótesis razonable en este dominio.
- MammoNet [71], una red bayesiana para la ayuda en la detección de cáncer de mama, que integra hallazgos procedentes de mamografía, factores demográficos y exploración física para determinar la probabilidad de malignidad.
- DynaMoL [84], un sistema de ayuda a la toma de decisiones en tiempo real, basado parcialmente en el formalismo de *diagramas de influencia dinámicos* [128]. Este sistema se aplica en la elaboración de planes óptimos para el seguimiento de pacientes de cáncer de colon que han sido tratados con cirugía [17].

Ni PATHFINDER ni MammoNet hacen uso de una representación explícita del tiempo, mientras que en DynaMoL el rango temporal se define como un conjunto de puntos temporales discretos, cada uno correspondiente a una cierta etapa de decisión.

## 7.2. Razonamiento temporal probabilista en medicina

Los métodos más ampliamente extendidos para el modelado en dominios médicos de procesos dinámicos sujetos a incertidumbre [4, 37, 69, 84, 87, 109] se basan en el formalismo de *redes bayesianas dinámicas* [38, 40, 74, 101] o su extensión, los *diagramas de influencia dinámicos* [128]. Como vimos en el capítulo 4, estos

formalismos poseen la desventaja de generar redes muy complejas, ya que discretizan el tiempo y crean un nodo para cada variable aleatoria asociada a un instante temporal. Normalmente generan una copia de una red estática por cada instante temporal y establecen enlaces entre nodos pertenecientes a redes estáticas adyacentes. De este manera consiguen modelar procesos markovianos en los que el futuro es condicionalmente independiente del pasado, dado el presente.

Además de los métodos presentados en la sección 4.3, todos ellos basados en el formalismo de redes bayesianas, a lo largo de los últimos años se han propuesto otros tipos de técnicas alternativas para la realización de razonamiento temporal probabilista en dominios médicos. A modo de ejemplo, Aliferis y Cooper [1, 2] desarrollan el lenguaje de *redes de creencia temporales modificables* como una ampliación estructural y temporal de las redes bayesianas. Ngo et al. [63, 100] definen una lógica probabilista temporal sensible al contexto, que permite representar redes bayesianas dinámicas.

El tiempo constituye un factor fundamental en cáncer ya que generalmente determina la etapa de desarrollo de la enfermedad y, en consecuencia, el tipo de tratamiento que se debe aplicar. Modelar el proceso que comienza cuando surge un tumor maligno y finaliza con la aparición de un conjunto de síntomas típicos, metástasis o afectación de ganglios linfáticos, requiere representar los mecanismos causales que controlan dicho proceso a lo largo del tiempo. El proceso de expansión de un cáncer, previamente a la aplicación de tratamiento, está formado por un conjunto de eventos irreversibles. Nuestra propuesta de modelado del crecimiento de un cáncer se basa en representar cada uno de estos eventos irreversibles por medio de un nodo en una REPTD.

### 7.3. Cáncer de nasofaringe

La nasofaringe es la parte superior de la faringe que recibe el aire que respiramos a través de la nariz. La cavidad nasofaríngea tiene forma cuboidal: las paredes laterales están formadas por la trompa de Eustaquio y la fosa de Rosenmüller; en la pared frontal se encuentran la parte posterior de las coanas y la cavidad nasal; la pared superior tiene la base del cráneo por encima; el límite posterior nasofaríngeo

está formado por los músculos de la pared posterior de la faringe y el límite inferior está compuesto por la superficie superior del velo del paladar y la pared posterior de la faringe.

Al ser la nasofaringe una cavidad de difícil acceso, localizada en la parte alta de la faringe, no es habitual efectuar una detección temprana de un tumor nasofaríngeo maligno. Los pacientes generalmente solicitan atención médica en etapas avanzadas de la enfermedad, cuando los síntomas resultan evidentes.

Un cáncer de nasofaringe [82, 118] surge en forma de tumor primario maligno localizado en una de las paredes nasofaríngeas (véase la figura 7.1). Los tumores primarios en las paredes laterales son los más frecuentes, mientras que los de las paredes anterior y posterior son menos probables. Con el paso del tiempo, un tumor primario inicial puede infiltrar el tejido adyacente (*tumor infiltrante*) o crecer en volumen dentro de la nasofaringe (*tumor vegetante*). En consecuencia, cualquier parte que rodee la nasofaringe o incluso cualquier pared nasofaríngea, se puede ver afectada por el crecimiento tumoral. Normalmente los tumores vegetantes pueden llegar a obstruir algunos de los conductos que conectan la nasofaringe con las partes que la rodean: cavidad nasal, oído o velo del paladar. Los tumores infiltrantes pueden alcanzar partes de vital importancia, como la base del cráneo o los nervios craneales. Los tumores infiltrantes de la nasofaringe son más invasivos que los vegetantes, aunque estos últimos requieren un período de tiempo menor para crecer. Los síntomas habituales del cáncer de nasofaringe son disfunciones relacionadas con la respiración, habla, visión, oído u olfato, entre otras. Por tanto, resulta crucial detectar la enfermedad en etapas de desarrollo tempranas; de otra manera, las consecuencias podrían resultar irreversibles para el paciente. Como en cualquier otro tipo de cáncer, existe la posibilidad de metástasis regional (afectación de ganglios linfáticos) o a distancia (pulmón, hígado...). La aparición de infección o hemorragia en la propia nasofaringe también constituye un signo de cáncer.

El proceso de diagnóstico de un cáncer de nasofaringe consta de tres fases:

- Registro de la historia clínica del paciente.
- Examen visual de la nasofaringe (por medio de espejo y rinoendoscopia) y documentación del tamaño y localización de los ganglios del cuello.

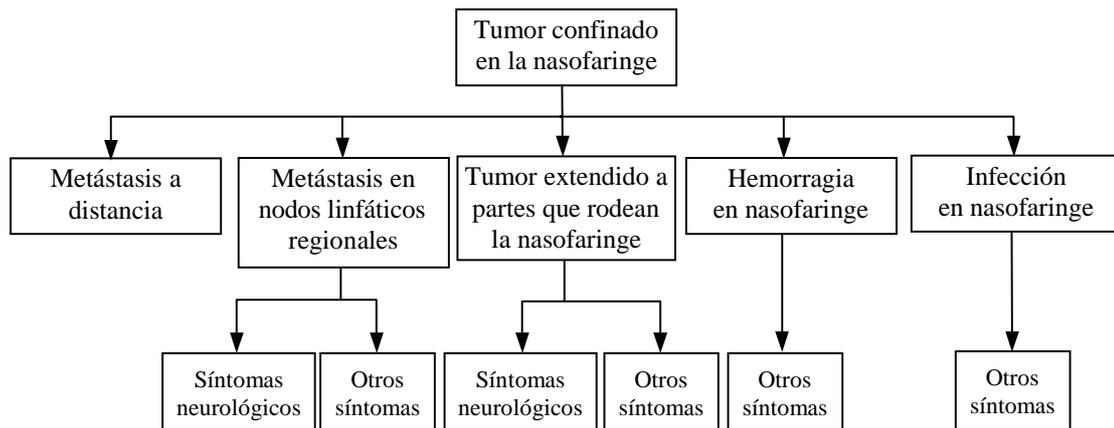


Figura 7.1: Esquema de la evolución de un cáncer de nasofaringe.

- Pruebas complementarias, tales como la evaluación del comportamiento de los nervios craneales y oído, biopsia, hemograma, tomografía o resonancia magnética que cubra los límites superior e inferior de la lesión.

Cada una de las fases anteriores produce nueva evidencia que ayuda al oncólogo en la determinación de la extensión y malignidad de la enfermedad.

Una vez completado el diagnóstico, la fase de desarrollo del cáncer se define por medio de la codificación TNM, donde T representa tumor primario, N ganglios linfáticos regionales y M metástasis a distancia. Por ejemplo, T1N0M1 significa “tumor confinado en la nasofaringe, ausencia de metástasis en nodos linfáticos regionales y presencia de metástasis a distancia”. El tratamiento adecuado (radiación, quimioterapia, cirugía...) depende de la etapa de desarrollo alcanzada por el cáncer.

## 7.4. NasoNet, una REPTD para cáncer de nasofaringe

### 7.4.1. Construcción del grafo causal

NasoNet [57, 58] es una REPTD que modela el proceso de expansión de un cáncer de nasofaringe. El modelo final sirve de ayuda al oncólogo en el diagnóstico y pronóstico de la extensión de este tipo de cáncer en un paciente.

Un tumor primario en cualquiera de las paredes o caras nasofaríngeas puede crecer e invadir partes adyacentes. También puede provocar metástasis a distancia, así como hemorragia o infección en la propia nasofaringe. Los procesos anteriores están caracterizados por la aparición de una serie de eventos. Tales eventos —antes de que el tratamiento sea aplicado— son generalmente irreversibles y están causalmente interrelacionados. Por ejemplo, un tumor vegetante primario en la cara anterior de la nasofaringe puede llegar a ocupar las fosas nasales y producir anosmia (pérdida del olfato); un tumor infiltrante primario en la cara superior de la nasofaringe puede extenderse a la cara lateral derecha, a continuación al seno cavernoso derecho, más tarde podría invadir el oído interno derecho y, finalmente, producir síntomas como acúfenos (zumbido en el oído), autofonía (resonancia de la voz propia), hipoacusia (disminución de la agudeza auditiva) y otros, todos ellos relacionados con anomalías en el oído. Algunos ejemplos de eventos relevantes en nuestro dominio son: “aparición de un tumor vegetante primario en la cara posterior de la nasofaringe”, “extensión de un tumor infiltrante al seno cavernoso izquierdo”, “aparición de rinolalia”, “aparición del síndrome de Gradenigo (parálisis de los nervios craneales V y VI) en el lado derecho”, “aparición de afectación de ganglios linfáticos cervicales en el lado izquierdo”, entre otros. En NasoNet, estos eventos y cualesquiera otros causalmente relacionados con la expansión de un cáncer de nasofaringe se representan como nodos de una REPTD.

Si hubiéramos decidido no representar explícitamente el tiempo en la red bayesiana, cada variable aleatoria (evento) podría tomar los valores *presente* o *ausente*; en consecuencia, únicamente habríamos necesitado variables aleatorias binarias. Por el contrario, al no ser instantáneos los procesos causales que estamos modelando y al existir incertidumbre en cuanto a su duración, necesitamos representar el tiempo explícitamente. Para tal fin, consideramos el instante en el que puede aparecer el tumor primario como el instante inicial de referencia, y definimos el tiempo de ocurrencia de cualquier otro evento con respecto a dicho instante inicial. Suponemos que existe únicamente un tumor primario, lo cual constituye una buena aproximación en nuestro dominio. De acuerdo con la opinión de los oncólogos, el rango temporal de interés en el caso del cáncer de nasofaringe son los tres años que siguen a la aparición del tumor primario. Este período lo dividimos en trimestres, siguiendo la opinión dada por los expertos médicos. El rango temporal y la unidad temporal finales fue-

ron elegidos teniendo en cuenta, por un lado, la viabilidad de la implementación computacional del modelo y, por otro lado, su expresividad temporal. Cada evento representado en la red posee un período típico de ocurrencia. Todos estos períodos están incluidos dentro del intervalo de tres años que hemos elegido como horizonte temporal. Por ejemplo, pueden aparecer ganglios linfáticos cervicales afectados durante el primer semestre y metástasis de pulmón durante el segundo o tercer año.

Tal como indicamos en la sección 5.1, el método de REPTDs permite hacer uso bien de tiempos absolutos bien de tiempos relativos a la ocurrencia de un determinado evento inicial (aparición del tumor primario en el caso de NasoNet). En el primer caso, cada valor que toma una variable representa un instante de tiempo absoluto en el que puede ocurrir su evento asociado. Una ventaja de usar tiempos absolutos consiste en que no se requiere la definición de diferentes escenarios (véase la sección 7.4.3). Sin embargo, si se usaran tiempos absolutos, cada evento de la red podría tener lugar en cualquiera de los instantes pertenecientes al rango temporal de interés (tres años en el caso de NasoNet). Por tanto, todas las variables podrían tomar el mismo número de valores (13 en nuestro dominio). En consecuencia, obtendríamos una red más compleja que en el caso de tiempos relativos. Ésta es la razón por la que inicialmente decidimos usar tiempos relativos en NasoNet.

Dado un nodo evento  $E$  cuyo período de ocurrencia está dividido en trimestres, la variable aleatoria asociada a  $E$  puede tomar en NasoNet los valores:

$$\{e[a], \dots, e[b], e[nunca]\} \quad \text{con } a, b \in \{1, \dots, 12\} \quad \text{y } a \leq b$$

El valor  $e[j]$ , con  $j \in \{a, \dots, b\}$ , significa que el evento  $E$  tiene lugar en el trimestre  $j$  después de la aparición del tumor primario y  $E = e[nunca]$  significa que  $E$  no tiene lugar. Por ejemplo, el valor *anosmia*[3] expresa la aparición de anosmia durante el tercer trimestre. Al poder tomar cada variable aleatoria un conjunto de valores exclusivos, cada evento asociado a una variable puede ocurrir sólo una vez a lo largo del tiempo. Esta condición se satisface en nuestro dominio, ya que los procesos existentes son irreversibles, previamente al tratamiento. (Los procesos reversibles podrían ser representados por medio de eventos múltiples pero no hemos necesitado representar ningún proceso reversible en NasoNet dado que nos ocupamos exclusivamente de la fase previa al tratamiento.)

La versión actual de NasoNet contiene en total 15 nodos asociados a tumores

confinados en la nasofaringe, 23 nodos que representan la expansión del tumor a partes que rodean la nasofaringe, 4 nodos que simbolizan metástasis a distancia, 4 nodos relacionados con la afectación de ganglios linfáticos, 11 nodos relacionados con infecciones o hemorragias en la nasofaringe y 50 nodos que hacen referencia a síntomas o síndromes, es decir, 107 nodos en total. Los nodos sin padres corresponden a eventos relacionados con la aparición de tumores primarios vegetantes o infiltrantes en cada cara de la nasofaringe. Al suponer que existe como máximo un tumor primario, las probabilidades de ocurrencia de los eventos asociados a los nodos sin padre anteriores junto con la probabilidad de ausencia de tumor primario deben sumar la unidad. Para tal fin, introducimos un nodo padre para tales nodos. Los nodos hoja de la red representan la aparición de diferentes síntomas o síndromes. Finalmente, los nodos intermedios son eventos relacionados con la expansión del tumor a partes adyacentes a la nasofaringe, infecciones, metástasis...

NasoNet modela la evolución de un cáncer de nasofaringe de manera que cada arco representa una relación causal entre un evento padre y un evento hijo. Por ejemplo, en la figura 7.2, la aparición de infección en la nasofaringe puede producir rinorrea (secreción excesiva de mucosa nasal). Si estas relaciones causales fueran estáticas, podríamos aplicar la puerta O probabilista para modelar las interacciones entre un efecto y sus causas. En el modelo de puerta O probabilista, cada causa actúa independientemente del resto de causas para producir un determinado efecto. Esta independencia de las interacciones causales se satisface en nuestro dominio, de acuerdo a la opinión de los expertos. Por ejemplo, la aparición de anosmia (véase la figura 7.2) puede ser provocada o bien por un tumor vegetante primario que ocupa la fosa nasal derecha o bien por la expansión de un tumor infiltrante a dicha fosa; en nuestro modelo, ambos procesos actúan independientemente el uno del otro.

Puesto que las relaciones causales en nuestro dominio no son instantáneas y, además, los nodos de la red corresponden a eventos temporales, usamos la puerta O probabilista temporal como modelo de interacción causal en la red. La puerta O probabilista temporal representa el caso en que el efecto está presente tan pronto como una cualquiera de sus causas provoque que esté presente. Según la figura 7.2, si un tumor vegetante primario en la cara lateral derecha provocara la aparición de una infección nasofaríngea en el trimestre  $i$ , y un tumor infiltrante primario provocara el mismo tipo de infección en el trimestre  $j$ , entonces se consideraría que el evento

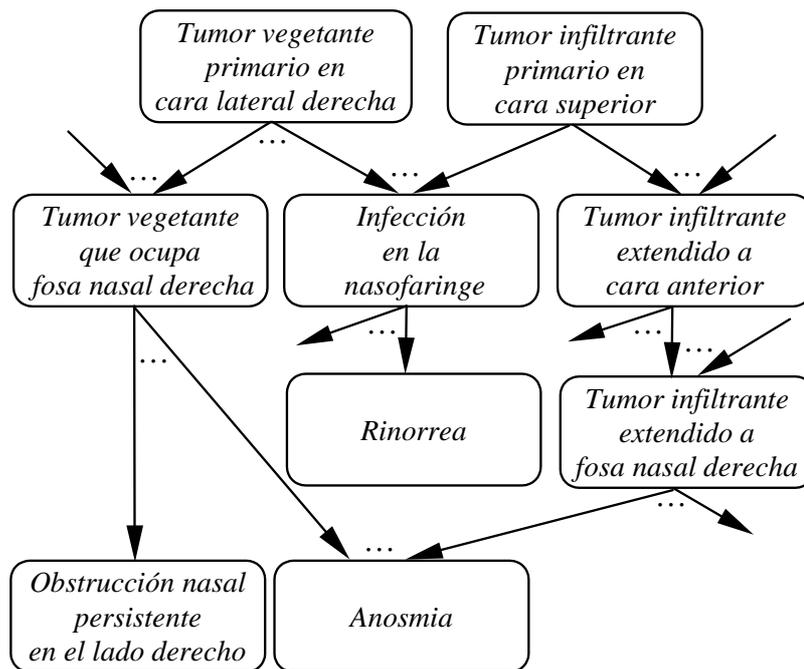


Figura 7.2: Parte de la red bayesiana que modela la evolución de un cáncer de nasofaringe.

“aparición de infección en la nasofaringe” ocurre en el trimestre  $\min(i, j)$ .

Consideremos una familia de nodos con  $n$  causas  $X_1, \dots, X_n$  y un efecto  $Y$ . En principio, cada uno de estos nodos evento puede tener lugar en cualquiera de los trimestres  $\{1, \dots, 12\}$ . Para cada causa, en el modelo de puerta O probabilista temporal es necesario especificar los parámetros:

$$c_{y[k_i]}^{x_i[j_i]} \quad i \in \{1, \dots, n\}, j_i \in \{1, \dots, 12, nunca\}, k_i \in \{1, \dots, 12\}$$

Cada parámetro se define como la probabilidad de que  $Y$  tenga lugar en  $k_i$ , dado que  $X_i$  tiene lugar en  $j_i$  y el resto de causas están ausentes. La tabla de probabilidades condicionales de  $Y$  se puede calcular según se indica en la sección 5.4.1.

### 7.4.2. Adquisición de los parámetros de la red

En principio, cada arco que forma parte de una puerta O probabilista temporal en NasoNet requiere  $(12 + 1) \cdot 12 = 156$  parámetros independientes. De entre estos

parámetros, aquéllos que cumplen

$$c_{y[k]}^{x_i[j_i=nunca]} \quad \text{con } k \in \{1, \dots, 12\}$$

son nulos, debido a que el efecto no puede tener lugar si ninguna de sus causas está presente. De los 144 parámetros restantes, si  $j_i > k$ , el parámetro es cero, ya que el efecto no puede preceder a la causa. Finalmente, los restantes 78 parámetros independientes pueden quedar reducidos a 12, puesto que en nuestro dominio, según la opinión de los expertos, es razonable suponer que se cumple la propiedad de *invariancia temporal*:

$$c_{y[k+\Delta t]}^{x_i[j_i+\Delta t]} = c_{y[k]}^{x_i[j_i]} \quad \text{con } j_i, k, j_i + \Delta t, k + \Delta t, \in \{1, \dots, 12\}$$

Esta propiedad expresa que si consideramos un retardo constante,  $k - j_i$ , entre la causa  $X_i$  y el efecto  $Y$ , los parámetros que definen el arco  $X_i \rightarrow Y$  son invariantes, independientemente de los instantes en que  $X_i$  e  $Y$  tienen lugar. En resumen, el cómputo de la tabla de probabilidades condicionales asociada a una familia de nodos en NasoNet requiere únicamente especificar un parámetro para cada posible retardo entre causa y efecto. Por tanto, para una familia de nodos con  $N$  padres, se necesitan  $12 \cdot N$  parámetros independientes como máximo en NasoNet. (Nótese que en el caso de interacción general entre los nodos padre este número se incrementaría hasta  $12 \cdot (12 + 1)^N$ ).

Las preguntas que el ingeniero de conocimiento tiene que formular a los oncólogos para la obtención de los parámetros son:

Dado que  $X_i$  tiene lugar en un cierto **trimestre**, ¿cuál es la probabilidad de que su efecto  $Y$  ocurra en el mismo trimestre si el resto de sus causas están ausentes? ¿Cuál es la probabilidad de que  $Y$  ocurra en el trimestre siguiente y así sucesivamente...?

Resultó difícil para los oncólogos poder responder a estas cuestiones. Argumentaban que las respuestas dependen de si el evento causa ocurre a principios o finales del trimestre. Sin embargo, se sintieron más seguros a la hora de responder a las preguntas siguientes:

Dado que  $X_i$  tiene lugar en un cierto **instante**, ¿cuál es la probabilidad de que su efecto  $Y$  ocurra en el siguiente trimestre si el resto de sus

causas están ausentes? ¿Cuál es la probabilidad de que  $Y$  ocurra en el trimestre siguiente al siguiente y así sucesivamente...?

Sean los parámetros correspondientes al último grupo de preguntas los siguientes:

$$\tilde{c}_Y^{X_i}(\Delta t) \quad \text{con} \quad \Delta t \in \{1, \dots, 12\}$$

Haciendo uso de una representación continua del tiempo, si  $X_i = x_i[1]$  entonces podemos asociar a  $X_i$  la función de densidad de probabilidad  $f_1$ , trazada en la figura 7.3.

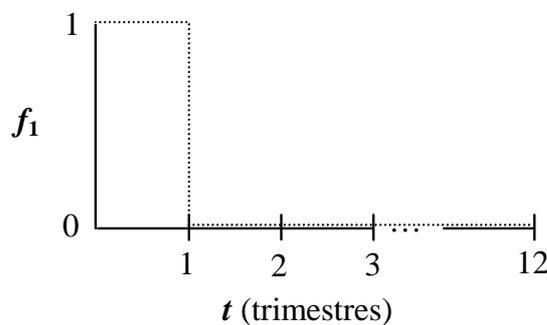


Figura 7.3: Función de densidad de probabilidad para  $X_i$  cuando  $X_i = x_i[1]$ .

La integral de la función de densidad de probabilidad entre dos instantes de tiempo es la probabilidad de ocurrencia del evento correspondiente entre esos dos instantes. Supongamos que

$$\tilde{c}_Y^{X_i}(\Delta t) = \begin{cases} k & \text{con } \Delta t = 1 \\ 0 & \text{con } \Delta t = \{2, \dots, 12\} \end{cases}$$

donde  $0 \leq k \leq 1$ . Estos parámetros, dados por los expertos médicos, definen una función de transferencia de probabilidad,  $f_2$ , entre  $X_i$  e  $Y$  (véase la figura 7.4), que representa el efecto de  $X_i$  sobre  $Y$ .

La función  $f$  de densidad de probabilidad para  $Y$  (véase la figura 7.5) se obtiene calculando la convolución de  $f_1$  y  $f_2$  (véase la sección 4.2 de [130]):

$$f(t) = \int_{-\infty}^{\infty} f_1(\tau) \cdot f_2(t - \tau) d\tau$$

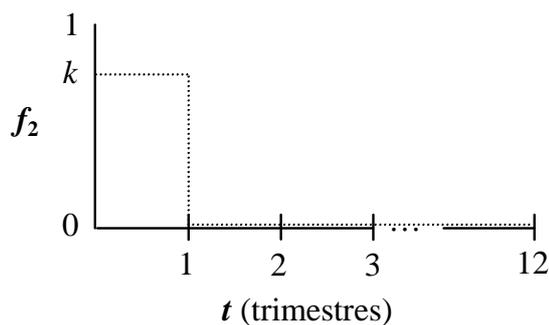


Figura 7.4: Función de transferencia de probabilidad entre  $X_i$  e  $Y$ .

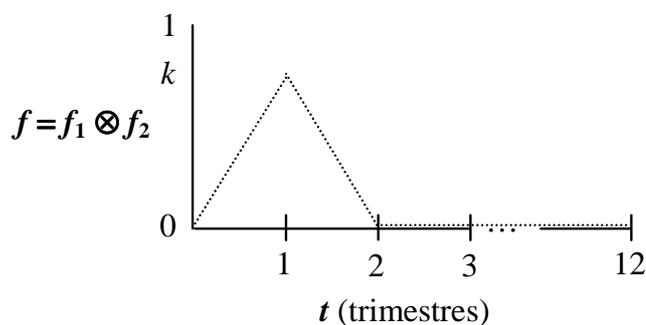


Figura 7.5: Función de densidad de probabilidad para  $Y$ .

Si a partir de la figura 7.5, retomamos la división del tiempo en trimestres, obtenemos:

$$c_{y[1]}^{x_i[1]} = \int_0^1 f dt = \frac{k}{2}$$

$$c_{y[2]}^{x_i[1]} = \int_1^2 f dt = \frac{k}{2}$$

En consecuencia, podemos concluir que, una vez que conocemos que  $X_i$  ha ocurrido en  $j_i$ , cada retardo particular  $\Delta t$  contribuye con la misma probabilidad a los trimestres  $j_i + \Delta t - 1$  y  $j_i + \Delta t$ . Por tanto,

$$c_{y[j_i+\Delta t]}^{x_i[j_i]} = \frac{\tilde{c}_Y^{X_i}(\Delta t)}{2} + \frac{\tilde{c}_Y^{X_i}(\Delta t + 1)}{2}$$

De este modo podemos calcular las tablas de probabilidades condicionales de la red a partir del conocimiento proporcionado por los expertos médicos.

Por citar un ejemplo, en la conexión *Tumor infiltrante extendido a cara anterior*  $\rightarrow$  *Tumor infiltrante extendido a fosa nasal derecha* (véase la figura 7.2), la

$c_{y[k]}^{x_i[j_i]}$	$x_i[1]$	$x_i[2]$	$x_i[3]$	$x_i[4]$	$x_i[nunca]$
$y[1]$	0.48/2	0	0	0	0
$y[2]$	(0.48 + 0.24)/2	0.24	0	0	0
$y[3]$	(0.24 + 0.12)/2	0.36	0.24	0	0
$y[4]$	(0.12 + 0.06)/2	0.18	0.36	0.24	0
$y[5]$	0.06/2	0.09	0.18	0.36	0
$y[6]$	0	0.03	0.09	0.18	0
$y[7]$	0	0	0.03	0.09	0
$y[8]$	0	0	0	0.03	0
$y[nunca]$	0.1	0.1	0.1	0.1	1

Tabla 7.1: Ejemplo de parámetros de un arco  $X_i \rightarrow Y$  en NasoNet.

información proporcionada por el experto es

$$\tilde{c}_Y^{X_i}(\Delta t) = \begin{cases} 0.48 & \Delta t = 1 \\ 0.24 & \Delta t = 2 \\ 0.12 & \Delta t = 3 \\ 0.06 & \Delta t = 4 \\ 0 & \Delta t = \{5, \dots, 12\} \end{cases}$$

Los parámetros finales de este arco se muestran en la tabla 7.1.

### 7.4.3. Ejemplo

En la elaboración de un diagnóstico asociado a un cáncer de nasofaringe, los oncólogos hacen uso de las fuentes de información siguientes: la historia clínica del paciente, el examen visual de la nasofaringe y el resultado de diferentes pruebas complementarias. Un hallazgo implica determinar la ocurrencia de un evento representado por medio de un nodo en NasoNet y establecer el tiempo en el que tuvo lugar. NasoNet determina, a partir de los hallazgos disponibles, tanto las probabilidades a posteriori como los tiempos de ocurrencia para el resto de eventos de la red. De cara a simplificar el ejemplo, supondremos que nuestro objetivo es doble: en primer lugar, queremos conocer si el tumor primario es vegetante o infiltrante y, en segundo lugar, estamos interesados en descubrir en qué cara está localizado el

tumor primario<sup>1</sup>.

Consideremos la porción de NasoNet mostrada en la figura 7.6. Cualquier tumor vegetante primario puede crecer en volumen dentro de la cavidad nasofaríngea y llegar a ocupar las fosas nasales. Esto puede llegar a producir rinolalia (voz nasal causada por una alteración en la resonancia de las fosas nasales). La aparición de un tumor vegetante primario puede también provocar la aparición de ganglios linfáticos cervicales afectados en el lado derecho. Los parámetros de la red de la figura 7.6 se muestran en la tabla 7.2.

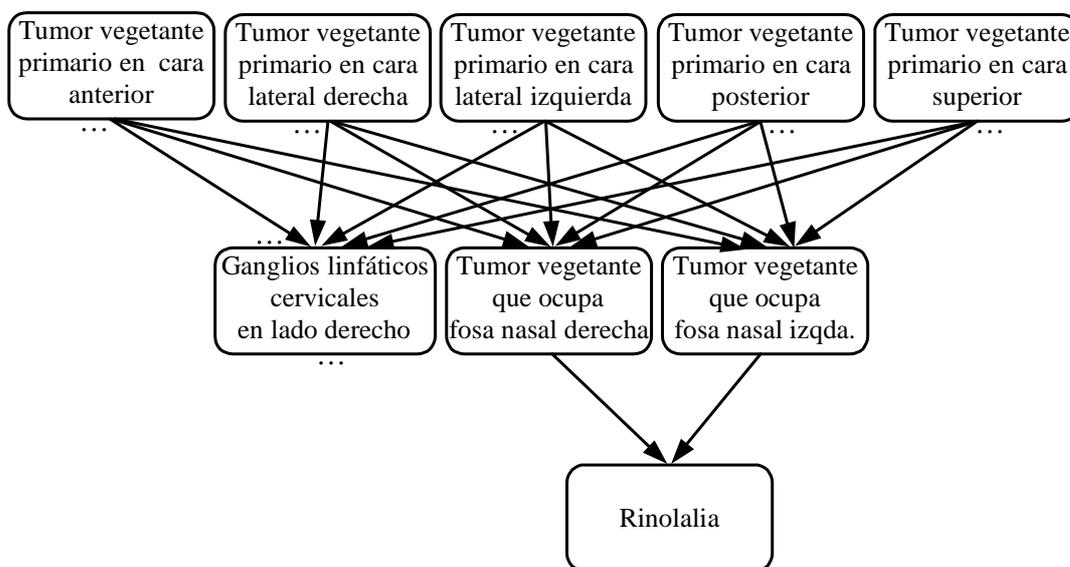


Figura 7.6: Subgrafo que forma parte de NasoNet.

Se sabe a partir de la anamnesis que el 20/9/1999 el paciente empezó a experimentar rinolalia. Con este único hallazgo, existen tantos escenarios posibles como retardos entre la aparición del tumor primario y la aparición de rinolalia, 12 en este caso. Para cada escenario se obtienen en NasoNet las probabilidades a posteriori que aparecen en la tabla 7.3.

La complejidad de la red impidió realizar la propagación de la evidencia a partir de algoritmos exactos. Este hecho resultó evidente una vez que se había introducido una representación explícita del tiempo para cerca de un tercio de los nodos que

<sup>1</sup>Nótese que estamos suponiendo que existe como máximo un tumor primario en el paciente, lo cual es una buena aproximación en este dominio.

$X_i$	$Y$	$\tilde{c}_Y^{X_i}(\Delta t)$
<i>Tvpca</i>	<i>Tvofnd</i>	0.225 para $\Delta t \in \{1, \dots, 4\}$
<i>Tvpca</i>	<i>Tvofni</i>	0.225 para $\Delta t \in \{1, \dots, 4\}$
<i>Tvpca</i>	<i>Glclld</i>	0.27 para $\Delta t = 1$ , 0.13 para $\Delta t = 2$
<i>Tvpclld</i>	<i>Tvofnd</i>	0.175 para $\Delta t \in \{3, \dots, 6\}$
<i>Tvpclld</i>	<i>Tvofni</i>	0.05 para $\Delta t \in \{3, \dots, 6\}$
<i>Tvpclld</i>	<i>Glclld</i>	0.27 para $\Delta t = 1$ , 0.13 para $\Delta t = 2$
<i>Tvpcli</i>	<i>Tvofnd</i>	0.05 para $\Delta t \in \{3, \dots, 6\}$
<i>Tvpcli</i>	<i>Tvofni</i>	0.175 para $\Delta t \in \{3, \dots, 6\}$
<i>Tvpcli</i>	<i>Glclld</i>	0.14 para $\Delta t = 1$ , 0.07 para $\Delta t = 2$
<i>Tvpcp</i>	<i>Tvofnd</i>	0.00625 para $\Delta t \in \{5, \dots, 12\}$
<i>Tvpcp</i>	<i>Tvofni</i>	0.00625 para $\Delta t \in \{5, \dots, 12\}$
<i>Tvpcp</i>	<i>Glclld</i>	0.27 para $\Delta t = 1$ , 0.13 para $\Delta t = 2$
<i>Tvpcs</i>	<i>Tvofnd</i>	0.175 para $\Delta t \in \{3, \dots, 6\}$
<i>Tvpcs</i>	<i>Tvofni</i>	0.175 para $\Delta t \in \{3, \dots, 6\}$
<i>Tvpcs</i>	<i>Glclld</i>	0.27 para $\Delta t = 1$ , 0.13 para $\Delta t = 2$
<i>Tvofnd</i>	<i>Rinolalia</i>	0.2, <i>instantáneo</i>
<i>Tvofni</i>	<i>Rinolalia</i>	0.2, <i>instantáneo</i>

Tabla 7.2: Parámetros de la red de la figura 7.6.

forman parte del grafo de NasoNet. El resultado anterior es consecuencia de la forma en que los entornos para el desarrollo de redes bayesianas realizan la propagación de la evidencia a partir de algoritmos exactos en redes con puertas probabilistas: en primer lugar, la puerta probabilista es transformada en una familia que interactúa según el modelo general y, entonces, se aplica un algoritmo exacto. Nótese que en el modelo general tanto el número de probabilidades condicionales como el tiempo para la propagación de la evidencia crecen exponencialmente con el número de padres. Una solución para este problema sería el uso de algoritmos exactos específicos para la propagación de la evidencia en redes con puertas probabilistas<sup>2</sup> [45, 49, 106, 126]. De cualquier modo, los algoritmos de simulación estocástica [55, 121] permiten obtener resultados aproximados aceptables en unos pocos minutos en NasoNet.

<sup>2</sup>La versión de NasoNet con tiempos relativos es anterior al desarrollo del trabajo sobre factorizaciones descrito en la sección 5.8.1.

		$Tvpca$	$Tvpcl$	$Tvpcli$	$Tvpcp$	$Tvpcs$	
<b>esc12:</b>	$rin[12]$	0	0	0	1	0	$\uparrow_{20/09/96}$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
<b>esc7:</b>	$rin[7]$	0	0	0	1	0	$\uparrow_{20/12/97}$
<b>esc6:</b>	$rin[6]$	0	0.4059	0.4072	0.0089	0.1778	$\uparrow_{20/03/98}$
<b>esc5:</b>	$rin[5]$	0	0.3817	0.386	0.0088	0.2233	$\uparrow_{20/06/98}$
<b>esc4:</b>	$rin[4]$	0.022	0.364	0.3629	0	0.2509	$\uparrow_{20/09/98}$
<b>esc3:</b>	$rin[3]$	0.0401	0.3434	0.3477	0	0.2686	$\uparrow_{20/12/98}$
<b>esc2:</b>	$rin[2]$	1	0	0	0	0	$\uparrow_{20/03/99}$
<b>esc1:</b>	$rin[1]$	1	0	0	0	0	$\uparrow_{20/06/99}$
							$\uparrow_{20/09/99}$

Tabla 7.3: Probabilidades a posteriori para tumores vegetantes primarios con localización temporal para cada escenario.

		$Tvpca$	$Tvpcl$	$Tvpcli$	$Tvpcp$	$Tvpcs$	
<b>esc1':</b>	$rin[1], glcld[2]$	1	0	0	0	0	$\uparrow_{30/06/99}$
							$\uparrow_{20/09/99}$

Tabla 7.4: Nuevas probabilidades a posteriori.

El 30/12/1999 el paciente detecta ganglios en la parte derecha del cuello. Finalmente es recibido en el Departamento de Oncología Radioterápica donde los oncólogos establecen mediante palpación la presencia de ganglios linfáticos cervicales anormales en el lado derecho. Puesto que la presencia de afectación en los ganglios linfáticos cervicales puede sólo ocurrir durante el semestre siguiente a la aparición del tumor primario (véase la tabla 7.2), únicamente un escenario es posible:  $rinolalia[1], glcld[2]$  (véase la tabla 7.4). Por tanto, podemos sospechar que el tumor primario está localizado en la cara anterior nasofaríngea. Éste es un resultado valioso que permite una mejor interpretación de la información obtenida a partir de pruebas complementarias posteriores.

El proceso de determinación del conjunto de escenarios resultantes a partir de una serie de hallazgos requiere: en primer lugar, establecer para cada hallazgo un período temporal (dividido en trimestres) de posible aparición del tumor primario de acuerdo al hallazgo, calcular después la intersección de los períodos anteriores y,

finalmente, elegir los posibles escenarios dentro de la intersección. La figura 7.7 ilustra un caso con tres hallazgos correspondientes a los eventos:  $A = \{a[1], a[2], a[3], a[4], a[nunca]\}$ ,  $B = \{b[1], b[2], b[3], b[nunca]\}$  y  $C = \{c[1], c[2], c[nunca]\}$ . Se obtienen los cuatro escenarios siguientes:  $esc1 \equiv \{a[2], b[2], c[2]\}$ ,  $esc2 \equiv \{a[1], b[2], c[2]\}$ ,  $esc3 \equiv \{a[1], b[1], c[2]\}$  y  $esc4 \equiv \{a[1], b[1], c[1]\}$ .

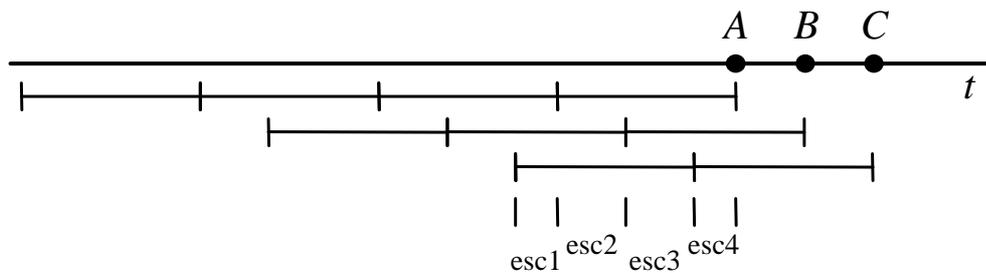


Figura 7.7: Posibles escenarios a partir de tres hallazgos.

Si en nuestro ejemplo el paciente hubiera empezado a padecer rinolalia después de la aparición de afectación en los ganglios linfáticos cervicales, habrían surgido nuevos escenarios relacionados con la aparición de tumor primario en otras caras aparte de la anterior, que podrían explicar la nueva evidencia. Este hecho muestra la importancia de usar una representación explícita del tiempo en este dominio, ya que el mismo tipo de eventos puede producir diagnósticos diferentes en función de los tiempos de ocurrencia de los eventos.

#### 7.4.4. Interfaz de NasoNet

La figura 7.8 muestra parte del grafo de la red bayesiana que constituye la base de NasoNet. Tal como se aprecia en la figura 7.8, no es posible visualizar todos los nodos en un única pantalla, por lo que se hace necesario utilizar barras de desplazamiento para acceder a las distintas partes del grafo. El no poder tener una imagen completa de la red resulta algo incómodo y desorientador, incluso a pesar de las facilidades de escalado que ofrece el entorno Elvira. Por tanto, la tarea de localización de un nodo concreto en la red no es inmediata para quien no esté familiarizado con el grafo que la forma.

Incluso en el caso de que el grafo completo de NasoNet se pudiera visualizar de

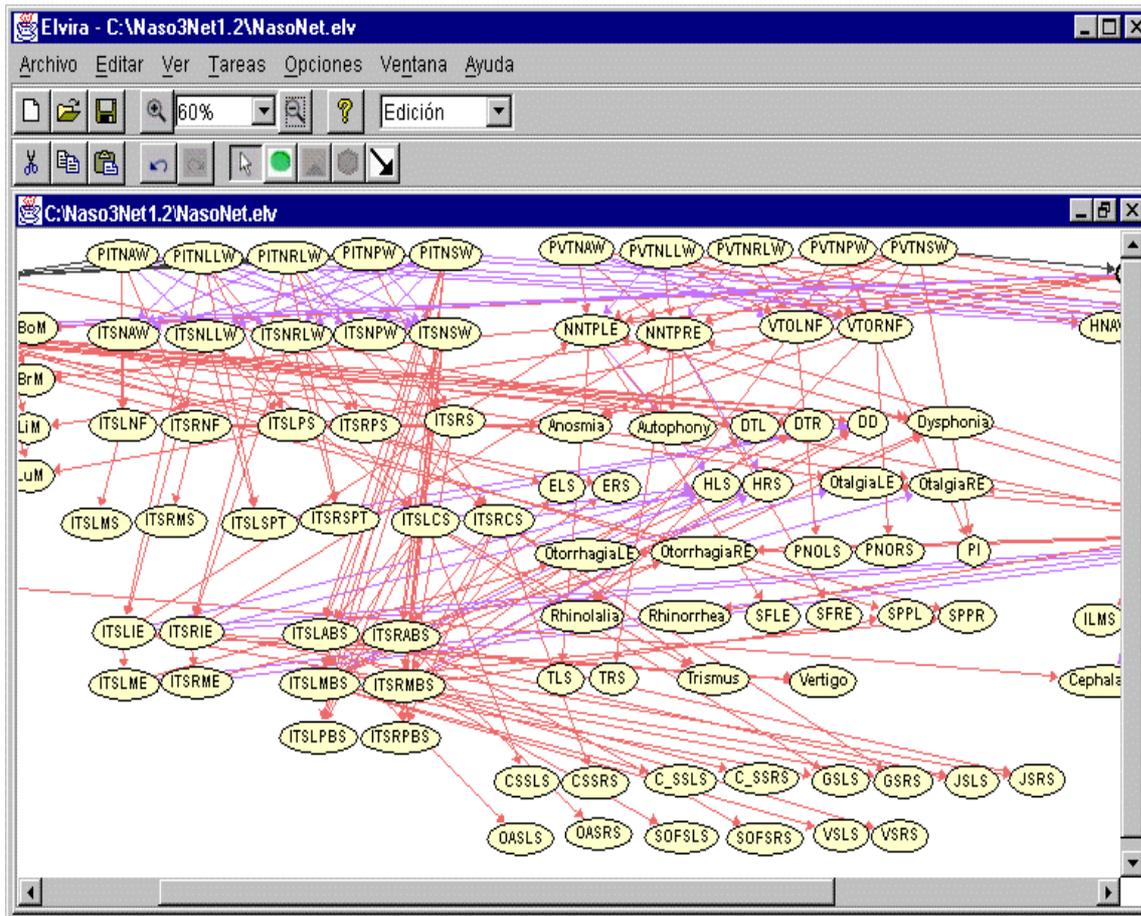


Figura 7.8: Parte del grafo de la red bayesiana de NasoNet.

forma completa, un grafo no parece la estructura más adecuada para que un oncólogo gestione de forma sencilla los datos necesarios para el estudio de la evolución de la enfermedad. Se necesita una manera de mostrar la información presente en los nodos que reordene dicha información según un punto de vista médico. Un buen punto de partida para la ordenación mencionada puede basarse en la clasificación previa establecida en la figura 7.1 en relación a los procesos que tienen lugar en el curso de la enfermedad: expansión del tumor, metástasis, síntomas, síndromes, hemorragias e infecciones.

Hay ciertos datos administrativos, como los datos personales del paciente, nombre del oncólogo, etc., que no quedan recogidos en una red bayesiana, debido a que dicha información no influiría en el diagnóstico. Estos datos, que aparecerían

normalmente en cualquier historia clínica, deben tener un espacio propio en el sistema. Además, la información temporal registrada sobre la ocurrencia de los distintos eventos asociados a la enfermedad debe ser tratada apropiadamente antes de poder ser introducida en la red bayesiana, una vez elegido por el oncólogo el rango temporal que desea considerar<sup>3</sup>. Esta tarea, que no puede ser realizada directamente por medio de la red bayesiana, debe ser completada por una interfaz creada a tal efecto.

Tras la realización de inferencia probabilística en una red bayesiana de más de un centenar de nodos, como es el caso de NasoNet, es bastante complicado consultar las probabilidades a posteriori obtenidas para un subconjunto cualquiera de los nodos de la red. En ocasiones, el interés residirá en poder comparar las probabilidades a posteriori obtenidas, por ejemplo, para dos nodos muy distantes entre sí en el grafo. Para poder realizar tal comparación de forma visual, la única solución es acercar lo máximo posible entre sí los dos nodos hasta que queden incluidos en la pantalla del ordenador. Esta solución, además de poco práctica, dista mucho de ser recomendable puesto que el grafo de una red bayesiana debería permanecer estático una vez que ha sido diseñado.

Como consecuencia de todo lo reseñado en esta sección, queda claro que resulta necesario diseñar una interfaz para la conexión de la red bayesiana temporal que constituye la parte central de NasoNet con el usuario, que en este caso será en principio un oncólogo. Por ello, hemos diseñado una interfaz para NasoNet utilizando el lenguaje JAVA. Esta interfaz está dotada de diferentes menús y botones que permiten hacer más amigable la interacción con el sistema (véase la figura 7.9). Existen dos modos principales de operación en la interfaz: introducción de evidencia y visualización de resultados de inferencia.

---

<sup>3</sup>La interfaz de NasoNet trabaja con tiempos absolutos ya que no resulta fácil para un oncólogo el manejo de los diferentes escenarios que aparecen en el caso de la red de tiempos relativos. La complejidad de la red de tiempos absolutos se puede reducir gracias al empleo de la factorización que describimos en la sección 5.8.1. A pesar de ello, la inferencia en la red con factorizaciones y tiempos absolutos sigue siendo más lenta que la que resulta de aplicar métodos aproximados en la red de tiempos relativos. El empleo de factorizaciones y la construcción de una interfaz para tiempos absolutos han sido en el tiempo los temas más recientes en los que hemos trabajado.

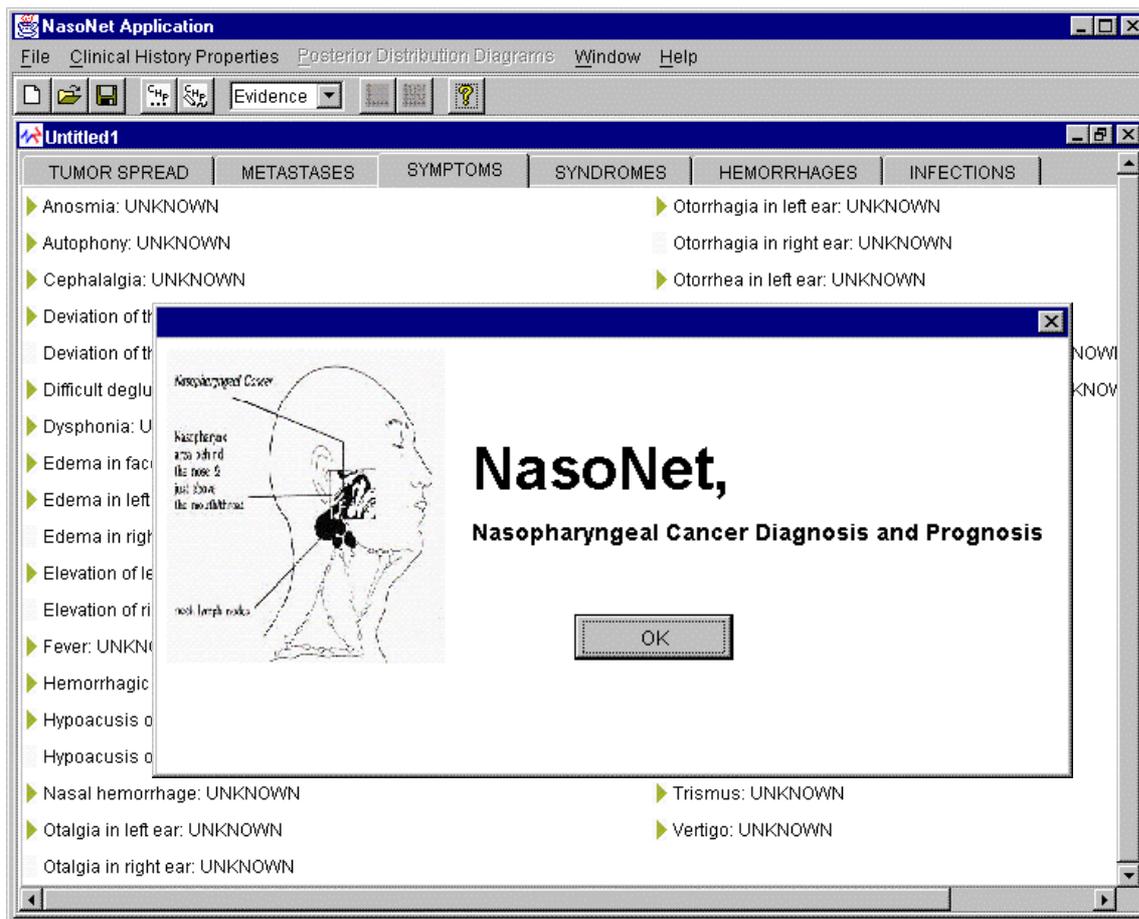


Figura 7.9: Pantalla principal de la interfaz de NasoNet.

### Modo de introducción de evidencia

El modo de introducción de evidencia de NasoNet permite introducir en el sistema el conjunto de eventos relacionados con la enfermedad y cuya ocurrencia conocemos con certeza.

Antes de entrar en modo de introducción de evidencia es necesario especificar la fecha actual. También existe la posibilidad de reseñar el nombre del paciente, nombre del oncólogo y cualquier tipo de comentario, tal como se indica en la figura 7.10.

Hemos agrupado los diferentes eventos asociados al desarrollo de un cáncer de nasofaringe en seis apartados:

The image shows a Windows-style dialog box titled "Case Properties". It has a blue title bar with a close button (X) on the right. The dialog contains the following elements:

- Case name: A text box containing "Untitled1".
- Patient: An empty text box.
- Oncologist: An empty text box.
- Comment: A large empty text area.
- Clinical History Date: A section containing radio buttons for each month (January, February, March, April, May, June, July, August, September, October, November, December). The "August" radio button is selected.
- Year: A text box containing "2000".
- Buttons: "OK" and "Cancel" buttons at the bottom.

Figura 7.10: Diálogo inicial de NasoNet.

- expansión tumoral, que aparece como “TUMOR SPREAD” en la figura 7.9,
- metástasis,
- síntomas,
- síndromes,
- hemorragias e
- infecciones.

Cada uno de estos apartados dispone de una pantalla completa para la introducción de evidencia. (La figura 7.9 muestra la correspondiente a la expansión tumoral.) En cada pantalla aparece una lista con una serie de eventos. Tras seleccionar uno de los eventos de la lista, aparece la ventana mostrada en la figura 7.11, que permite

especificar bien el mes de ocurrencia del evento seleccionado o bien la ausencia de dicho evento hasta la fecha actual.

The image shows a dialog box titled "Event Occurrence". It contains the text "APPEARANCE TIME FOR: Anosmia". Below this is a grid of radio buttons for months: January (selected), February, March, April, May, June, July, August, September, October, November, and December. Below the grid is a "Year" label followed by a text input field. At the bottom are three buttons: "Event absent", "No evidence on this event", and "Accept" and "Cancel".

Figura 7.11: Ventana para la especificación del período de ocurrencia de un evento.

Asociada a cada evento existe una breve explicación de su significado desde un punto de vista médico. A modo de ejemplo, *anosmia* se define como un síntoma consistente en la *pérdida completa del sentido del olfato*. A través de la interfaz es posible acceder a la explicación creada para un evento cualquiera sin más que situar durante un par de segundos la flecha del ratón sobre la etiqueta asociada al evento, lo cual representa una ayuda para aquel usuario que no es un experto en cáncer de nasofaringe.

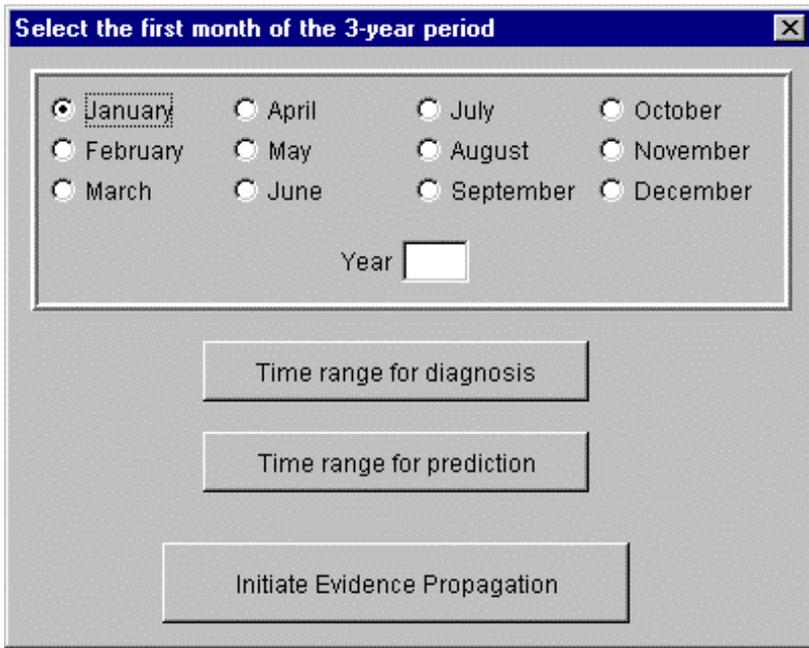
Toda la información introducida por el oncólogo puede ser almacenada en un fichero de extensión “.nas”, tal como el mostrado a continuación:

```
>>NasoNet case <<
File caso1 {
Patient = ''paciente1'';
```

```
Oncologist = ''oncologo1'';
Date = ''09/2002'';
Comment = ''comentarios correspondientes al caso1'';
Tumor spread events {
}
Metastasis events {
>Brain metastasis: 07/2002
>Affected cervical lymph nodes on the right side: 03/2002
}
Symptom events {
>Anosmia: 04/2002
}
Syndrome events {
}
Hemorrhage events {
}
Infection events {
}
}
```

### Modo de visualización de resultados de inferencia

Una vez que hemos completado la introducción de evidencia para un determinado caso en NasoNet, podemos entrar en modo de visualización de resultados de inferencia. Al entrar en este modo de operación, lo primero que se nos pide es definir el rango temporal de tres años durante el que se va a estudiar la evolución de la enfermedad. La ventana mostrada en la figura 7.12 es la que se encarga de la definición del rango temporal anterior.



The image shows a software window titled "Select the first month of the 3-year period". Inside the window, there is a grid of radio buttons for selecting a month. The "January" radio button is selected. Below the grid is a "Year" input field. At the bottom of the window, there are three buttons: "Time range for diagnosis", "Time range for prediction", and "Initiate Evidence Propagation".

Figura 7.12: Ventana para la definición del rango temporal de tres años.

Existen tres posibilidades para la elección del rango temporal de interés, dado un conjunto de eventos cuya ocurrencia conocemos con certeza:

- elección del rango temporal para diagnóstico,
- elección del rango temporal para predicción y
- elección de un rango temporal cualquiera según criterio del usuario.

Definimos el *rango temporal para diagnóstico* como aquél que finaliza coincidiendo con el último evento conocido, tal como se indica en la figura 7.13. A su vez, el *rango temporal para predicción* sería aquél que comienza coincidiendo con el primer evento conocido (véase la figura 7.13). La interfaz permite hallar cualquiera de los dos rangos anteriores, una vez conocidos los eventos que forman parte de la evidencia sobre el estado del paciente.

La apariencia de la pantalla para la visualización de los resultados de la inferencia es, en principio, similar a la pantalla que aparecía en el modo de introducción de evidencia: varias listas de eventos agrupados según su relación con la enfermedad.

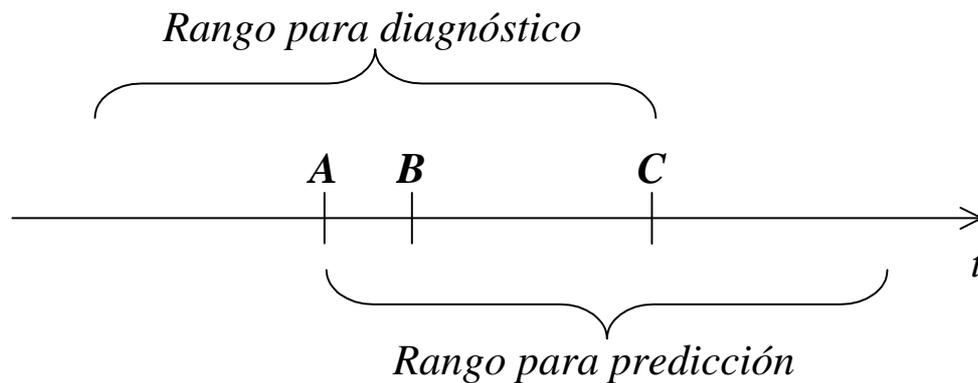


Figura 7.13: Ejemplo de rangos temporales para diagnóstico y predicción, dados los eventos  $A$ ,  $B$  y  $C$ .

Sin embargo, las diferencias empiezan a hacerse ostensibles al seleccionar cualquiera de los eventos. Tras dicha selección, se le ofrece al usuario la posibilidad de ver la probabilidad a posteriori del evento seleccionado (véase la figura 7.14) o de obtener una gráfica de la distribución de probabilidades mencionada.

En la pantalla que muestra las gráficas de las distribuciones de probabilidad a posteriori, existe la posibilidad de ver dibujadas varias gráficas a la vez, correspondientes a varios eventos seleccionados por el usuario, tal como se muestra en la figura 7.15. El color con el que se traza cada gráfica particular puede ser elegido por el usuario. Si así se desea en un momento dado, se pueden borrar todas las gráficas dibujadas hasta entonces para posteriormente incorporar un nuevo grupo de eventos. En cualquier momento sería posible regresar desde el modo de visualización de probabilidades a posteriori al modo de introducción de evidencia.

### Ventajas aportadas por la interfaz de NasoNet

La interfaz descrita en párrafos previos aporta como principales ventajas las siguientes:

- La localización de un evento cualquiera relacionado con la enfermedad resulta más rápida como consecuencia de la clasificación y ordenación de eventos.
- Además de los datos concernientes exclusivamente a la evolución de la enfer-

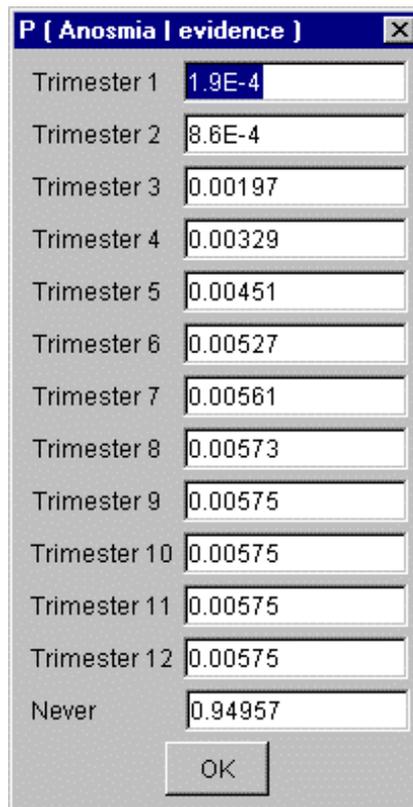


Figura 7.14: Probabilidades a posteriori numéricas para el evento “aparición de anosmia”.

medad en el paciente, la interfaz permite incluir nuevos datos sobre el caso tratado, que completan la historia clínica del paciente.

- El tratamiento de la información temporal se realiza automáticamente, de manera que no es necesario calcular manualmente la correspondencia entre las fechas en que ocurren los eventos y sus valores temporales asociados en la red bayesiana. Además, dado un determinado caso con una serie de eventos asociados, la interfaz puede obtener los rangos de diagnóstico y predicción.
- La visualización de los resultados de la inferencia probabilística resulta más sencilla, atractiva y reveladora gracias a las utilidades gráficas diseñadas.
- Finalmente, reseñar que realizamos un cambio cualitativo en el sistema paralelamente al diseño de la interfaz. Dicho cambio consistió en el empleo de tiempos absolutos en todos los nodos y la creación de una red transformada

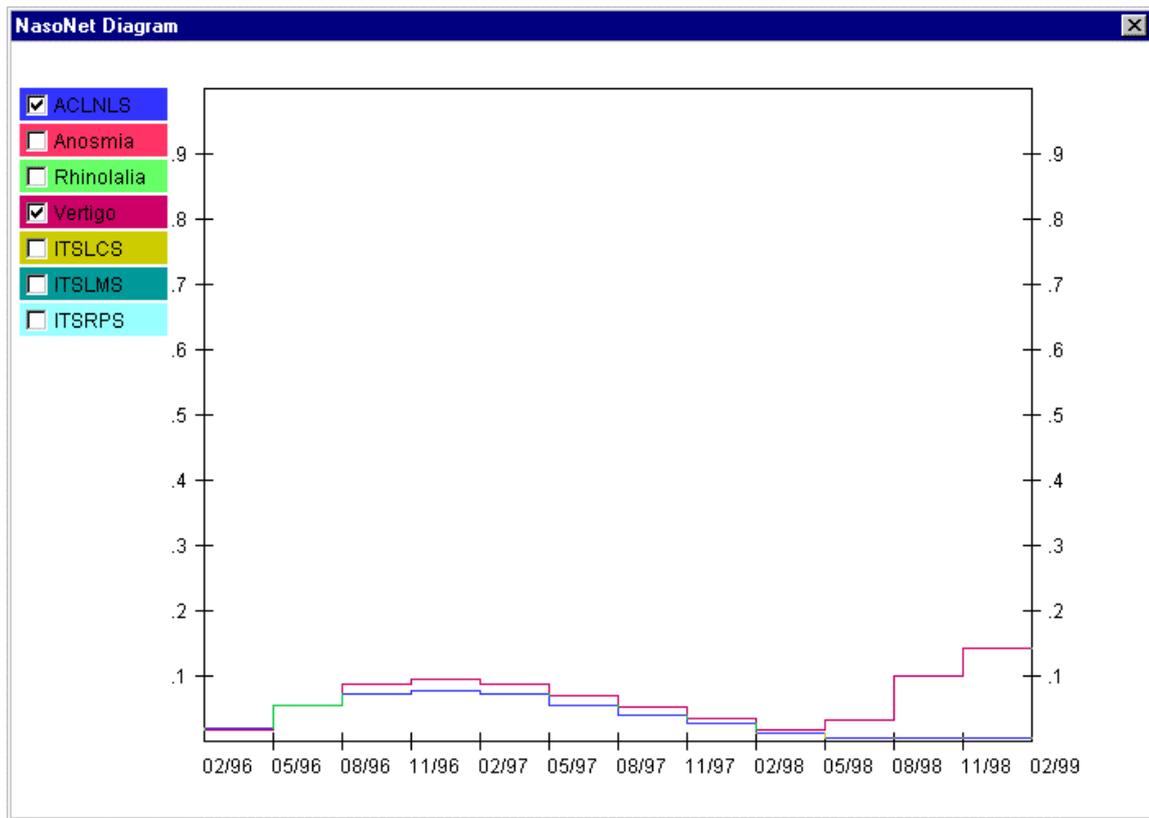


Figura 7.15: Pantalla para las gráficas de las distribuciones de probabilidad a posteriori.

según las directrices marcadas en la sección 5.8.1. Como consecuencia de lo anterior, ya no se manejaron diferentes escenarios como en el caso de tiempos relativos (véase la sección 7.4.1), sino un único rango temporal absoluto de tres años establecido por el usuario.

#### 7.4.5. Evaluación de NasoNet

A lo largo de esta sección consideramos únicamente la versión de NasoNet con tiempos relativos. Esta versión es anterior en el tiempo a la que hace uso de tiempos absolutos, así como a la factorización descrita en la sección 5.8.1.

Como paso previo a la construcción final de NasoNet, desarrollamos una red bayesiana atemporal en la que cada nodo representa la ocurrencia o no de un cierto evento. El grafo de esta red (véase la figura 7.8) es el mismo que el de NasoNet y el

tipo de interacción causal para cada familia de nodos sigue el modelo de puerta O probabilista.

Comprobamos que el conjunto de nodos de la red describiera la enfermedad con el grado de detalle adecuado. Después de un cierto número de entrevistas con los expertos médicos, decidimos simplificar determinadas partes del grafo y ampliar otras. Por ejemplo, el modelo inicial detallaba la extensión del tumor a cada uno de los agujeros del cráneo atravesados por los nervios craneales. Más adelante decidimos agrupar dichos agujeros para formar partes más significativas. De modo recíproco, inicialmente sólo consideramos el concepto general de “tumor primario en la nasofaringe”. Posteriormente, se hizo necesario realizar una diferenciación de tumores primarios según la pared nasofaríngea en la que se había originado. El grafo inicial fue diseñado siguiendo una estrategia en anchura, es decir, para todas las causas de un determinado nivel del grafo se generaban todos sus efectos. Esta forma de trazar el grafo es análoga a la forma en que el cáncer se expande a lo largo del tiempo. La verificación de los arcos de la red fue llevada a cabo siguiendo una estrategia diferente. Ordenamos los nodos alfabéticamente y asociamos a cada nodo sus posibles causas. De esta manera forzamos a los oncólogos a considerar el grafo en sentido ascendente. Además, el orden alfabético obligaba a los oncólogos a razonar localmente en la red, debido a que cada nodo no tenía ahora ninguna relación directa con su predecesor según el orden alfabético. La red atemporal consta de 276 arcos con múltiples bucles. Una vez introducidas las probabilidades a priori y condicionadas en la red, la propagación de la evidencia mediante algoritmos de agrupamiento llevaba alrededor de un segundo.

La introducción de una representación explícita del tiempo en la red motivó el uso de variables multivaluadas, así como del modelo de puerta O probabilista temporal. El número medio de valores que podía tomar cada variable en la versión temporal alcanzó un valor de 9'6. La verificación de los parámetros en esta versión de NasoNet se vio facilitada por la construcción previa de la red atemporal, en la que se establecía una probabilidad condicional para cada arco. Sin embargo, la red temporal asociaba un vector de probabilidades condicionales a cada arco, de tal manera que cada probabilidad condicional estaba relacionada con un retardo determinado entre causa y efecto. La consistencia del sistema requería que en cada arco la suma de los componentes de su vector de probabilidades condicionales en la red temporal

fuera igual a la probabilidad condicional de la red atemporal.

Hemos realizado una evaluación previa de NasoNet partiendo de los datos contenidos en ocho historias clínicas reales<sup>4</sup>, los cuales fueron comparados con los resultados obtenidos para cada caso a partir de la red. Se realizaron los siguientes pasos para cada historia clínica:

- Introducción en la red de la evidencia disponible sobre el caso. Generalmente, entre cuatro y ocho hallazgos temporales.
- Propagación de la evidencia en la red.
- Comparación del resto de la información presente en la historia clínica con las probabilidades a posteriori obtenidas en NasoNet.

Para cada paciente, NasoNet proporciona un conjunto de probabilidades a posteriori  $\{p^*(e[t_i^E]), \dots, p^*(e[t_f^E]), p^*(e[nunca])\}$ , donde  $t_i^E$  y  $t_f^E$  representan los límites del rango temporal del evento  $E$ . ( $E$  es cualquier evento que no está incluido como evidencia en la historia clínica del paciente.) La información sobre cuándo ocurrió realmente el evento  $E$  ( $t_{\text{real}}^E \in \{t_i^E, \dots, t_f^E, nunca\}$ ) se obtiene a partir de la historia clínica y se compara con las probabilidades a posteriori, siguiendo tres métodos diferentes:

1. Para cada evento  $E$ , comprobamos si se cumple

$$p^*(e[t_{\text{real}}^E]) = \max_{j \in \{t_i^E, \dots, t_f^E, nunca\}} \{p^*(e[j])\}$$

y calculamos el porcentaje de eventos de la red que hacen que la igualdad anterior se satisfaga.

2. Otra opción es considerar en el método previo, no sólo el valor temporal con probabilidad a posteriori más alta, sino el par de valores temporales con probabilidades a posteriori más altas.

---

<sup>4</sup>En los últimos años, la Unidad de Oncología Radioterápica del Hospital Clínico Universitario San Carlos de Madrid ha estado temporalmente fuera de servicio debido a la realización de diferentes trabajos encaminados a su mejora. Este hecho, unido a la baja incidencia del cáncer de nasofaringe en España, ha imposibilitado que pudiéramos conseguir un mayor número de historias clínicas.

3. Finalmente, es interesante estudiar el porcentaje de eventos correctamente diagnosticados o predichos por NasoNet, independientemente del tiempo en el que ocurrieron. En este caso, únicamente consideramos si los eventos ocurren o no. Ahora, un evento  $E$  es correctamente diagnosticado o predicho cuando

$$\begin{cases} \left( \sum_{j=t_i^E}^{t_f^E} p^*(e[j]) \right) > p^*(e[nunca]) & \text{si } t_{\text{real}}^E \neq nunca \\ \left( \sum_{j=t_i^E}^{t_f^E} p^*(e[j]) \right) < p^*(e[nunca]) & \text{en caso contrario} \end{cases}$$

La tabla 7.5 resume los resultados obtenidos a partir de cada uno de los tres métodos. Según el punto de vista de los expertos médicos, dichos resultados reflejan una ejecución satisfactoria por parte del sistema en lo que se refiere a la obtención de diagnósticos correctos.

Obsérvese que en la columna correspondiente al segundo método, los porcentajes de eventos correctamente diagnosticados superan en alrededor de un 5% de media a los porcentajes que aparecen en la primera columna. El resultado anterior no resulta extraño si se tiene en cuenta el hecho de que, en algunos eventos, los dos primeros valores más altos de probabilidad a posteriori se diferencian poco. Por otra parte, en la tabla 7.5 los porcentajes obtenidos a partir del segundo y tercer métodos son muy similares. Por tanto, en líneas generales podemos afirmar que cuando el sistema indica acertadamente la ocurrencia de un determinado evento (tercer método), lo hace en el período temporal correcto (primer o segundo método).

## 7.5. Discusión

Según el método de REPTDs, se discretiza el tiempo y cada valor de una variable representa el instante en el que puede ocurrir un cierto evento. Ésta es la principal diferencia con respecto a las redes bayesianas dinámicas, en las que el valor de una variable  $V_i$  representa el estado de una propiedad del mundo real en el instante  $t_i$ . Por tanto, una REPTD resulta más apropiada para el diagnóstico de fallos temporales ya que sólo se necesita una variable para representar la ocurrencia de un fallo y, en consecuencia, las redes resultantes son mucho más simples que las que se obtienen usando redes bayesianas dinámicas. Por el contrario, las redes bayesianas

	<b>Método 1</b>	<b>Método 2</b>	<b>Método 3</b>
<i>paciente 1</i>	90.1 %	92.8 %	93.9 %
<i>paciente 2</i>	84 %	92 %	90 %
<i>paciente 3</i>	82.7 %	89.5 %	87.5 %
<i>paciente 4</i>	87 %	92.5 %	91 %
<i>paciente 5</i>	83.5 %	90 %	88.3 %
<i>paciente 6</i>	90 %	92.5 %	92 %
<i>paciente 7</i>	86 %	91 %	92.7 %
<i>paciente 8</i>	85.2 %	90.1 %	89.2 %

Tabla 7.5: Porcentaje de eventos correctamente diagnosticados o predichos.

dinámicas son más apropiadas para tareas de monitorización puesto que representan explícitamente el estado del sistema en cada momento. Un ejemplo de este tipo de tareas es la planificación de terapia en diabetes [69].

Las redes bayesianas dinámicas tienen la desventaja de generar redes muy complejas [9]. Si hubiéramos decidido aplicar este formalismo a nuestro dominio, habría sido necesario copiar el grafo causal de NasoNet —con más de un centenar de nodos— doce veces. Sin embargo, solamente se necesita una copia si se usa una REPTD. Además, la aplicación de redes bayesianas dinámicas se restringe usualmente a procesos markovianos en los que el futuro es condicionalmente independiente del pasado dado el presente, es decir, sólo se permiten conexiones entre variables aleatorias pertenecientes al mismo instante o a instantes consecutivos. En nuestro dominio, por el contrario, un mecanismo causal puede en general durar un trimestre, dos trimestres... o incluso años.

Las REPTDs son similares a las redes bayesianas con nodos temporales de Arroyo Figueroa y Súcar, aunque estas últimas carecen de una formalización de modelos canónicos para procesos temporales. En el caso general, es necesario asignar a cada nodo de una red bayesiana un conjunto de probabilidades condicionales que crece exponencialmente con el número de padres. Esto complica la adquisición de los parámetros, su almacenamiento y la propagación de la evidencia. Por estas razones se desarrollaron nuevos modelos de interacción causal —llamados modelos canónicos— de cara a simplificar tanto el proceso de construcción de una red bayesiana como

el cómputo de la probabilidad. En una familia de nodos que interactúan según un modelo canónico, el número de parámetros requeridos crece linealmente con el número de padres. Las investigaciones previas a la construcción de NasoNet nos condujeron al desarrollo de modelos canónicos temporales dentro del enfoque de REPTDs. Existen nodos en NasoNet cuyo número de padres se eleva a seis. Habría sido imposible usar el modelo general de interacción causal en tales familias, mientras que la elicitación de los parámetros numéricos de NasoNet resultó relativamente fácil.

## Capítulo 8

# Diagnóstico y predicción de fallos en un generador de vapor de una central termoeléctrica

Un generador de vapor de una central termoeléctrica está sujeto a perturbaciones que pueden provocar fallos en su funcionamiento. El diagnóstico y predicción de estos fallos se debe realizar teniendo en cuenta la incertidumbre propia del dominio y su carácter dinámico.

Arroyo Figueroa y Súcar desarrollaron un formalismo denominado *red bayesiana con nodos temporales* (RBNT) (véase la sección 4.3.2), que aplicaron al modelado de fallos en un generador de vapor de una central termoeléctrica. A pesar de que la fase de evaluación del modelo produjo resultados satisfactorios, existen ciertos aspectos del formalismo que pueden ser mejorados.

El trabajo descrito en el presente capítulo pretende, por una parte, aplicar al mismo dominio el nuevo tipo de red bayesiana para razonamiento temporal que hemos denominado *red de eventos probabilistas en tiempo discreto* y, por otra parte, analizar si el modelo resultante produce algún tipo de mejora respecto al modelo que aplica RBNTs.

## 8.1. Modelado del diagnóstico y predicción de fallos en un generador de vapor

La aparición y propagación de fallos en un generador de vapor de una central termoeléctrica es un proceso dinámico no determinista. Un sistema que modele dichos fallos debe integrar la representación de la incertidumbre y el tiempo.

Las redes bayesianas constituyen un formalismo capaz de manejar incertidumbre, basado en la teoría de la probabilidad. Desde su aparición en los años ochenta, se han aplicado con éxito en medicina, sistemas para la enseñanza, economía, etc.

Arroyo Figueroa y Súcar aplicaron el formalismo de RBNT [5, 6, 7] al diagnóstico y predicción de fallos en un generador de vapor de una central termoeléctrica. Este modelo temporal probabilista se basa en asociar a cada nodo de una red bayesiana el cambio de estado de una variable, que puede producirse en diferentes intervalos de tiempo. Una RBNT es un método computacionalmente más eficiente que otros modelos de redes bayesianas temporales [8, 72, 74, 117] cuando hay que modelar procesos irreversibles; tal es el caso de los fallos que se producen en un generador de vapor de una central termoeléctrica. Una desventaja que presenta el formalismo de RBNTs es que utiliza exclusivamente el modelo de interacción general para cualquier familia de nodos de la red. En este tipo de interacción es necesario especificar para cada nodo hijo un número de probabilidades condicionales que crece exponencialmente con el número de padres. Esto representa un inconveniente para la adquisición, a partir de un experto o de una base de datos, de las probabilidades condicionales asociadas a cada enlace de la red y para la propagación de la evidencia. Sin embargo, la utilización de modelos canónicos de interacción causal (puertas O, Y... probabilistas) ofrece grandes ventajas respecto al modelo de interacción general ya que:

- Requiere únicamente la especificación para cada familia de nodos de un número de probabilidades condicionales proporcional al número de padres.
- La adquisición de las probabilidades condicionales y a priori asociadas a los nodos de la red, así como la propagación de la evidencia, resultan menos complejas que en el caso general.

- Los modelos canónicos de interacción causal están directamente relacionados con la noción intuitiva humana de causalidad, por lo que es mucho más fácil desarrollar mecanismos de explicación del razonamiento mediante estos modelos. (La capacidad de explicación del razonamiento es una de las características que todo sistema experto debe poseer.)

Tal como hemos visto en capítulos anteriores, una REPTD es un tipo de red bayesiana para razonamiento temporal que resulta apropiada para dominios relacionados con el diagnóstico y predicción de fallos producidos a lo largo del tiempo. En este método se discretiza el tiempo, se asocian nodos de la red a eventos y cada uno de los valores que toma un nodo representa la ocurrencia de un evento en un determinado instante o intervalo temporal. Se supone que cada evento puede ocurrir sólo una vez a lo largo del tiempo. Una ventaja fundamental de una REPTD es que permite hacer uso de diferentes puertas probabilistas temporales que facilitan la adquisición y representación del conocimiento.

El proceso de aparición sucesiva de fallos en un generador de una central termoeléctrica está formado por una serie de eventos irreversibles. Cada uno de estos eventos se puede representar por medio de un nodo de una REPTD. En este capítulo mostramos la aplicación del método de REPTDs al modelado de la evolución de los fallos temporales de un generador de vapor de una central termoeléctrica. Además, comparamos el modelo final con aquél que resulta de la aplicación de RBNTs.

## 8.2. REPTD para diagnóstico y predicción de fallos en un generador de vapor

El generador de vapor de una central termoeléctrica está formado por un conjunto de equipos cuya finalidad es producir energía eléctrica por medio de la generación de vapor a partir de combustibles fósiles. El generador debe proporcionar vapor en condiciones adecuadas de presión y temperatura para el correcto funcionamiento de las turbinas del generador eléctrico.

La figura 8.1 muestra la estructura general de un generador de vapor de una central termoeléctrica.

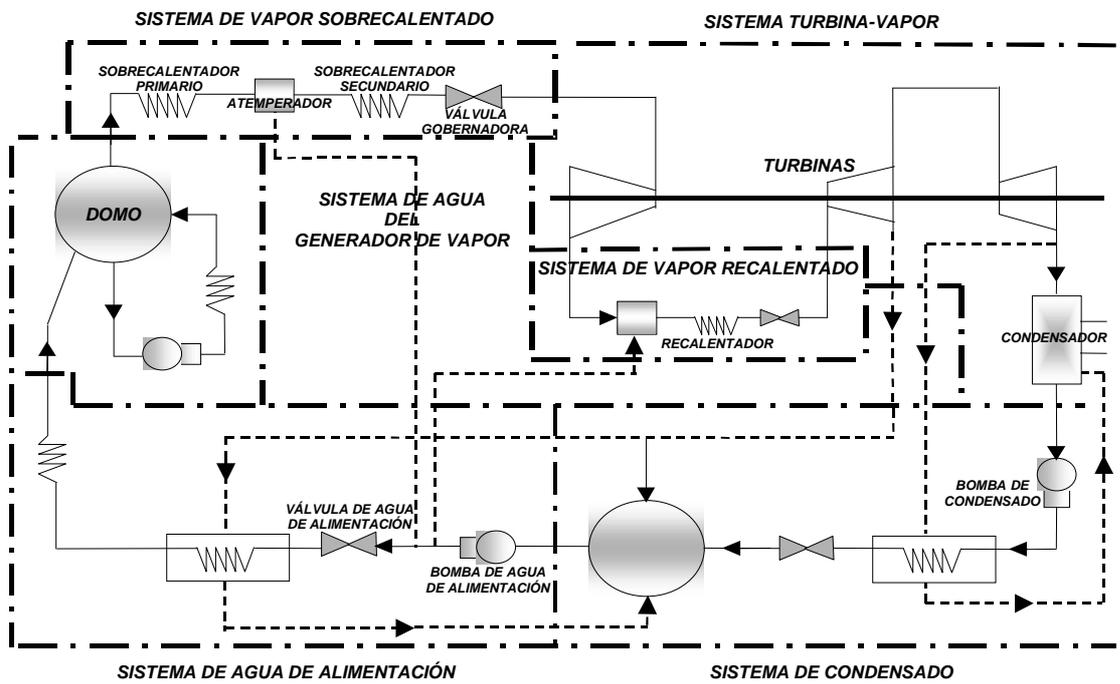


Figura 8.1: Esquema de la estructura de un generador de vapor de una central termoeléctrica. (Tomado de [6].)

El proceso de generación de vapor comienza con la combustión de un material fósil en una caldera. La energía liberada se transmite a agua en estado líquido contenida en tuberías que rodean las paredes de la caldera. El vapor saturado que se forma es sobrecalentado y conducido a la turbina de alta presión. Una vez utilizado, el vapor es recalentado y utilizado en turbinas de media y baja presión. Finalmente, el vapor remanente es condensado, dando término al ciclo agua-vapor. El presente trabajo se centra en el estudio de los siguientes subsistemas de un generador de vapor de una central termoeléctrica:

**Sistema de agua de alimentación:** Su función consiste en mantener un nivel suficiente de agua dentro del domo: colector superior de la caldera donde se produce la separación del agua y el vapor. Dicho nivel se ajusta mediante unas válvulas controladas por un sistema que usa como parámetro el nivel de agua del domo.

**Sistema de agua del generador de vapor:** Su función es proveer vapor saturado seco para que sea posteriormente sobrecalentado. Este subsistema permite separar el agua en estado de vapor saturado seco del agua en estado líquido saturado. Existen una serie de válvulas que permiten ajustar el paso de vapor principal.

**Sistema de vapor sobrecalentado:** Tiene como función principal proveer vapor sobrecalentado en condiciones adecuadas de presión y temperatura a la turbina de alta presión. Existen unas válvulas de atemperación que se ajustan en función de la temperatura del vapor sobrecalentado.

En la figura 8.2 aparecen los distintos tipos de perturbaciones que se pueden presentar durante el funcionamiento de los subsistemas considerados con anterioridad, así como las relaciones de causalidad existentes entre los mismos. Dicha información fue obtenida a partir de expertos en el dominio y constituye el modelo causal utilizado por Arroyo Figueroa y Súcar para la construcción de su RBNT.

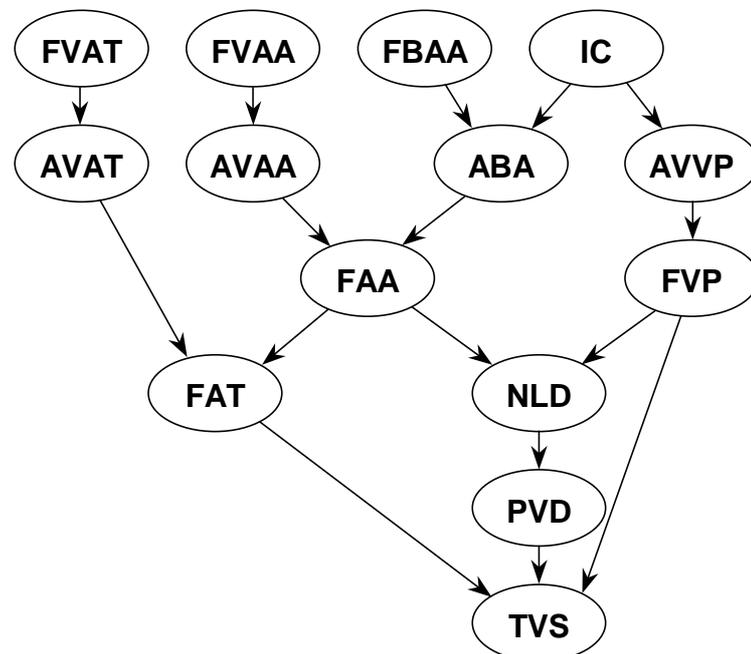


Figura 8.2: Grafo de la RBNT que modela los posibles fallos de un generador de vapor.

El significado de cada uno de los nodos de la figura 8.2 es el siguiente:

1. **ABA**: aumento de la velocidad de la bomba de agua de alimentación.
2. **AVAA**: incremento en la apertura de la válvula de agua de alimentación.
3. **AVAT**: incremento en la apertura de la válvula de agua de atemperación.
4. **AVVP**: incremento en la apertura de la válvula de vapor principal.
5. **FAA**: incremento en el flujo de agua de alimentación.
6. **FAT**: incremento en el flujo de agua de atemperación.
7. **FBAA**: fallo en la bomba de agua de alimentación.
8. **FVAA**: fallo en la válvula de agua de alimentación.
9. **FVAT**: fallo en la válvula de agua de atemperación.
10. **FVP**: incremento en el flujo de vapor principal.
11. **IC**: incremento de carga (o capacidad de generación de la central).
12. **NLD**: incremento o decremento en el nivel de agua del domo.
13. **PVD**: decremento en la presión del domo.
14. **TVS**: decremento en la temperatura del vapor sobrecalentado.

Se pueden presentar cuatro tipos principales de perturbaciones en un generador de vapor de una central termoeléctrica:

- Si se pretende que la central incremente su capacidad de generación de energía (IC), se ajusta la apertura de la válvula de vapor al nuevo nivel deseado (AVVP). Esto provoca un aumento del flujo de vapor (FVP). Por otra parte, IC provoca un aumento de la velocidad de la bomba de agua de alimentación (ABA), lo cual provoca un incremento en el flujo de agua de alimentación (FAA). Aunque FAA tendería a aumentar el nivel del domo (NLD se incrementa), el efecto provocado por FVP prevalece, de manera que finalmente se

produce un descenso en el nivel del domo (NLD se decrementa). La disminución en NLD provoca un decremento de la presión del vapor sobrecalentado (PVD), lo cual provoca una disminución de la temperatura del vapor sobrecalentado (TVS) antes de alcanzar las nuevas condiciones estables correspondientes al nivel de carga solicitado.

- Si se produce un fallo en el sistema de control del agua de alimentación (FBAA), se incrementa la velocidad de la bomba de agua (ABA), lo cual provoca un incremento en el flujo de agua de alimentación (FAA). Esto provoca que el nivel del domo se incremente (NLD se incrementa), la presión del vapor sobrecalentado disminuya (PVD) y la temperatura del vapor sobrecalentado disminuya (TVS). Esta perturbación puede provocar una condición de paro en el domo.
- Si se produce un fallo en el sistema de control del nivel de agua del domo (FVAA), la válvula de control de agua se abre al máximo (AVAA). Esto genera un incremento en el flujo de agua de alimentación (FAA), lo cual provoca que el nivel del domo se incremente (NLD se incrementa), la presión del vapor sobrecalentado disminuya (PVD) y la temperatura del vapor sobrecalentado disminuya (TVS). Esta perturbación puede provocar una condición de paro en el domo.
- Si se produce un fallo en el sistema de control de temperatura del vapor sobrecalentado (FVAT), la válvula de control de flujo de atemperación se abre al máximo (AVAT), lo cual genera un incremento en el flujo de agua de atemperación (FAT). Esto provoca que la temperatura del vapor sobrecalentado disminuya (TVS). Esta perturbación puede conducir a una condición de paro por la baja temperatura del vapor sobrecalentado que llega a la turbina principal.

### 8.2.1. Nuevo modelo causal del dominio

El modelo causal de la figura 8.2, que fue utilizado por Arroyo Figueroa y Súcar para la construcción de su RBNT, no es directamente trasladable a una REPTD. Esto es así debido a que el nodo NLD, que representa la disminución o el aumento del

nivel del domo, no constituye un evento único. En realidad representa dos posibles eventos: uno asociado al aumento en el nivel del domo debido al aumento del flujo de agua de alimentación (FAA), y otro asociado a su disminución debido al aumento del flujo de vapor principal (FVP).

El modelo causal que nosotros proponemos aparece en la figura 8.3. En este nuevo modelo causal se introducen los nodos evento NLDA y NLDD, que representan el aumento y disminución a priori del nivel del domo, respectivamente. El aumento o disminución real del nivel del domo se establece en el nodo NLD, al igual que en el modelo de la figura 8.2. El valor que tome NLD dependerá del orden temporal relativo entre los eventos NLDA y NLDD, tal como se explica en la próxima sección. Por tanto, NLDA y NLDD no son nodos observables y nunca se introducirá evidencia en ellos. La evidencia que se tenga sobre el aumento o disminución del nivel del domo se introducirá en el nodo NLD.

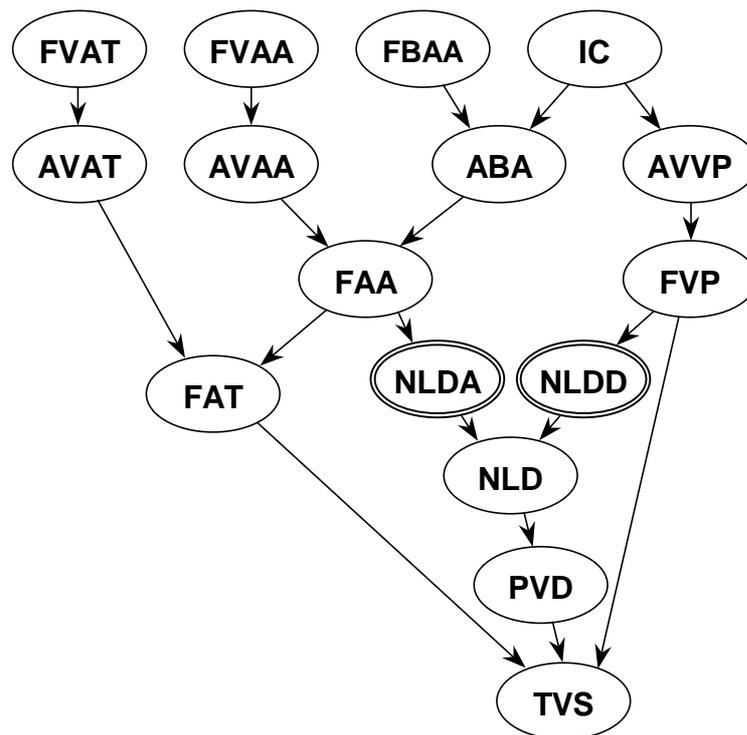


Figura 8.3: Grafo de la REPTD que modela los fallos en un generador de vapor.

### 8.2.2. Obtención de los parámetros de la REPTD

El rango u horizonte temporal de nuestro modelo es de 12 minutos<sup>1</sup>. Este período lo dividimos en intervalos de 20 segundos. Hay, por tanto, 36 intervalos diferentes en los que puede ocurrir cualquier evento representado en la figura 8.3. Dado cualquier nodo evento  $E$ , la variable asociada a  $E$  puede tomar los valores  $\{e[1], \dots, e[36], e[nunca]\}$ , donde  $e[i]$  representa que  $E$  ha tenido lugar en el intervalo  $i$ , mientras que  $e[nunca]$  representa que  $E$  no ha tenido lugar dentro del rango temporal considerado. Por ejemplo,  $FAT = fat[3]$  significa “incremento en el flujo de agua de atemperación producido el tercer intervalo, es decir, entre los segundos 41 y 60”. Por tanto, nuestro modelo para el generador de vapor hace uso de tiempos absolutos.

Debido a que cada variable aleatoria no puede tomar más que un valor, su evento asociado puede ocurrir sólo una vez a lo largo del tiempo. Esto se cumple en nuestro dominio, donde los fallos que tienen lugar en el generador de vapor corresponden a procesos irreversibles. Para restablecer el correcto funcionamiento del generador después de la aparición de un fallo, debe producirse la intervención de un operador humano.

Usamos la puerta O probabilista temporal como modelo de interacción causal dentro de la red. En este modelo, cada causa actúa para producir un determinado efecto, independientemente de la presencia o no del resto de causas. Esta propiedad de independencia causal se satisface en nuestro dominio, según opinión de los expertos consultados. Por ejemplo, un aumento en el flujo de agua de alimentación (FAA) puede ser producido por un aumento en la apertura de la válvula de agua de alimentación (AVAA) o por un aumento en la velocidad de funcionamiento de la bomba de agua de alimentación (ABA); ambos procesos actúan independientemente.

También nos indicaron los expertos que en este dominio existe invariancia temporal. Por tanto, dado un nodo evento sin padres, a cada valor asociado a la ocurrencia del evento en un cierto intervalo le corresponde la misma probabilidad a priori,  $\varepsilon$ , próxima a 0.

En nuestro sistema, el cálculo de la tabla de probabilidades condicionales asociada a una familia de nodos (excepto para el nodo NLD, que es el único que no

---

<sup>1</sup>El rango temporal de 12 minutos se estableció tras consultar con los Profs. Arroyo Figueroa y Súcar.

interactúa con sus nodos padre mediante una puerta O probabilista temporal) requiere especificar un parámetro  $c_{y[k]}^{x_i[j_i]}$  para cada posible retardo entre la causa  $X_i$  y el efecto  $Y$  cuando el resto de causas están ausentes. Es decir, dado que  $X_i$  tiene lugar en un cierto intervalo de 20 segundos, hay que especificar cuál es la probabilidad de que su efecto  $Y$  ocurra en ese mismo intervalo, si el resto de sus causas están ausentes, además de la probabilidad de que  $Y$  ocurra en el siguiente intervalo y así sucesivamente. Los únicos datos de los que disponíamos para calcular estos parámetros corresponden a los generados mediante simulación por Arroyo Figueroa y Súcar en la construcción de su RBNT. En concreto, hemos utilizado aquel subconjunto de datos que representa los tiempos relativos de ocurrencia de un efecto  $Y$  en relación a una de sus causas  $X_i$  cuando el resto de causas estaban ausentes. La tabla 8.1 muestra el conjunto de datos disponibles para el arco FBAA  $\rightarrow$  ABA.

10	10	10	10	11	11	11	11	12
12	12	12	12	12	12	12	13	13
13	13	15	15	15	15	18	18	18
18	20	20	20	20	20	20	20	20
21	21	21	21	21	21	21	21	22
22	22	22	27	27	27	27	29	29
29	29	29	29	29	29	29	29	29
29	31	31	31	31	32	32	32	32

Tabla 8.1: Retardos (en segundos) asociados al arco FBAA  $\rightarrow$  ABA para 72 pruebas diferentes en el simulador.

Cada número de la tabla 8.1 representa el retardo en segundos existente entre la ocurrencia de FBAA y la de ABA para una prueba determinada. A partir de parámetros como los que contiene la tabla 8.1 es inmediato obtener los parámetros que hemos llamado  $\tilde{c}_Y^{X_i}(\Delta t)$  en el capítulo 7. Estos parámetros establecen, dado que  $X_i$  tiene lugar en un cierto instante, cuál es la probabilidad de que su efecto  $Y$  ocurra en el siguiente intervalo de 20 segundos si el resto de sus causas están ausentes, cuál es la probabilidad de que  $Y$  ocurra en el intervalo siguiente al siguiente y así sucesivamente. En el caso del enlace de la tabla 8.1, tenemos

$$\tilde{c}_{ABA}^{FBAA}(1) = \tilde{c}_{ABA}^{FBAA}(2) = 0.5$$

Tal como se vio en la sección 7.4.2, se verifica que

$$c_{y[j_i+\Delta t]}^{x_i[j_i]} = \frac{\tilde{c}_Y^{X_i}(\Delta t)}{2} + \frac{\tilde{c}_Y^{X_i}(\Delta t + 1)}{2} \quad (8.1)$$

Por tanto, a partir de los datos numéricos de que disponemos, la ecuación 8.1 permite calcular los parámetros necesarios para el cómputo de las tablas de probabilidades condicionales de la red.

Como hemos dicho antes, suponemos que en nuestro dominio se cumple la propiedad de *invariancia temporal*:

$$c_{y[k]}^{x_i[j_i]} = c_{y[k+\Delta t]}^{x_i[j_i+\Delta t]}$$

Además, cuando ninguna causa está presente, el efecto tampoco puede estarlo:

$$c_{y[k]}^{x_i[j_i=nunca]} = 0$$

Finalmente, el efecto no puede ocurrir antes que la causa que lo provoca:

$$c_{y[k]}^{x_i[j_i>k]} = 0$$

El nodo NLD no interactúa con sus nodos padre mediante el modelo de puerta O probabilista temporal. Este nodo puede tomar los valores  $\{disminuye[1], \dots, disminuye[36], aumenta[1], \dots, aumenta[36], sin-cambio\}$ . Representando *disminuye* por *d* y *aumenta* por *a*, el tipo de interacción que sigue el nodo NLD es el siguiente:

$$P(nld \mid nlda[j], nldd[k]) = \begin{cases} 0 & \text{si } (nld = d[i] \text{ o } nld = a[i]) \text{ e } (i < j \text{ e } i < k) \\ 1 & \text{si } nld = a[i] \text{ y } j = i \text{ y } j < k \\ 1 & \text{si } nld = d[i] \text{ y } k = i \text{ y } k < j \\ 0.5 & \text{si } (nld = d[i] \text{ o } nld = a[i]) \text{ e } (i = j = k) \end{cases}$$

El valor 0.5 previo corresponde al caso en que a priori el nivel del domo puede aumentar o disminuir en el mismo intervalo de 20 segundos. Como en principio no hay nada que nos dé idea de qué tipo de cambio se produce antes, asociamos probabilidades iguales a los valores de aumento y disminución del nivel del domo correspondientes a ese intervalo.

Debido a que hemos utilizado un modelo de interacción causal en la red que requiere únicamente un número de parámetros proporcional al número de padres de

un efecto, hemos necesitado menos datos que los requeridos para construir la RBNT correspondiente. En concreto, sólo hemos necesitado recurrir a pruebas en las que existía un único fallo inicial, de manera que en cada familia de nodos como máximo una de las causas estaba presente. Por el contrario, la construcción de la RBNT requirió además simular fallos múltiples, de manera que en cada familia de nodos cualquier distribución de valores de las causas fuera posible. Lo anterior supone una ventaja de nuestro modelo frente al de RBNTs.

### 8.2.3. Ejemplo

Pretendemos estudiar la evolución de los posibles fallos surgidos en un generador de vapor entre las 10:00:00 hrs. y las 10:12:00 hrs. de la mañana. Dicho rango queda dividido en intervalos de 20 segundos de duración, tal como indica la figura 8.4. Consideramos, por tanto, 36 intervalos de tiempo diferentes.

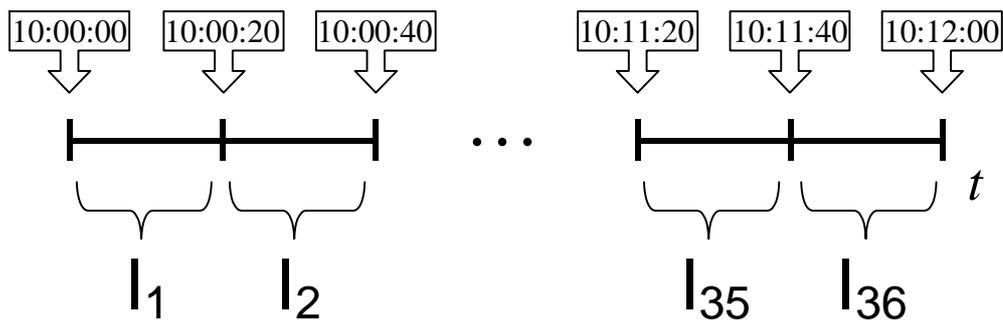


Figura 8.4: Rango temporal del ejemplo.

Estamos interesados en conocer, a partir de la evidencia disponible sobre los eventos que ocurren en el generador, qué perturbación inicial (FVAT, FVAA, FBAA o IC) es la más probable y en qué intervalo temporal dentro del rango considerado se originó.

A las 10:06:50 hrs. se produce un primer hallazgo de evidencia correspondiente a la aparición de un incremento en la velocidad de funcionamiento de la bomba de agua de alimentación (ABA). Por tanto,  $ABA = aba[21]$  ya que el evento correspondiente al fallo en la bomba ocurre dentro del intervalo  $I_{21}$ . Si realizamos la propagación de

la evidencia en la red a partir de este primer hallazgo, obtenemos un importante aumento en la probabilidad de ocurrencia de los fallos FBAA e IC, tal como se puede apreciar en la tabla 8.2. Cabe recordar que cuando no existía evidencia, la probabilidad a priori de estos eventos era prácticamente 0 para cada uno de los intervalos.

	...	$I_{15}$	$I_{16}$	$I_{17}$	$I_{18}$	$I_{19}$	$I_{20}$	$I_{21}$	...	<i>nunca</i>
$P(fbaa aba[21])$	...	0	0	0	0	0.098	0.197	0.098	...	0.605
$P(ic aba[21])$	...	0.029	0.067	0.163	0.198	0.11	0.038	$\approx 0$	...	0.394

Tabla 8.2: Probabilidades a posteriori para  $aba[21]$ .

A las 10:07:45 hrs. se produce un segundo hallazgo, consistente esta vez en la disminución de la temperatura del vapor sobrecalentado (TVS). En este caso, se tiene  $TVS = tvs[24]$ . La introducción de este nuevo hallazgo en la red tiene como consecuencia el que la probabilidad a posteriori del nodo FBAA baje prácticamente a cero para cualquier intervalo. Por tanto, IC es ahora el único tipo de fallo que permite explicar la evidencia del dominio. Las probabilidades a posteriori para cada intervalo de tiempo asociado a IC aparecen en la tabla 8.3. Obsérvese que ahora la probabilidad de que IC no ocurra ha bajado prácticamente a cero.

	...	$I_{15}$	$I_{16}$	$I_{17}$	$I_{18}$	$I_{19}$	$I_{20}$	...	<i>nunca</i>
$P(ic aba[21], tvs[24])$	...	0.002	0.023	0.182	0.448	0.283	0.058	...	$\approx 0$

Tabla 8.3: Probabilidades a posteriori para  $aba[21]$  y  $tvs[24]$ .

### 8.3. Discusión

La REPTD que modela el proceso de propagación de fallos en un generador de vapor ha sido implementada utilizando la herramienta de uso libre Elvira, descrita en el capítulo 6.

El cálculo de las probabilidades a posteriori a partir de la evidencia disponible dura en Elvira entre unos pocos segundos y menos de un minuto, por lo que este sistema podría ser utilizado en una central termoeléctrica como método de ayuda para los operadores humanos en el diagnóstico y predicción de fallos en tiempo real. Por otra parte, hemos utilizado algoritmos exactos para el cálculo de las probabilidades a posteriori de las variables de la red.

La evaluación de la RBNT de Arroyo Figueroa y Súcar se realizó mediante un simulador de una unidad termoeléctrica de 350 MW, que emula el comportamiento de la unidad termoeléctrica número 1 del complejo Manzanillo II en México [129], y mediante un sistema de adquisición de datos y registro de eventos. La metodología de evaluación de la RBNT se basó en la determinación de dos parámetros: *porcentaje de aciertos* y *medida de Brier*. El proceso de simulación permitió obtener un conjunto de datos, de los cuales el 80 % se utilizó para determinar las probabilidades a priori y condicionales de la red, y el 20 % restante para evaluar las capacidades de predicción y diagnóstico del formalismo. En total se generaron 972 casos de prueba correspondientes a perturbaciones simples, dobles y triples en el incremento de carga, las válvulas de agua de alimentación, las válvulas de agua de atemperación o la bomba de agua de alimentación. Se considera que ocurre un fallo cuando el valor de una variable se desvía en un 5 % de su valor de normalidad. Este incremento es utilizado por los operadores humanos de una central termoeléctrica para establecer si una variable del proceso presenta un cambio significativo. Debido a problemas para la recuperación de los datos utilizados en su momento por Arroyo Figueroa y Súcar para la evaluación de su sistema, aún no hemos podido llevar a cabo la evaluación exhaustiva de nuestra REPTD, que esperamos poder realizar en un futuro próximo.

Aunque se puede considerar que el formalismo de RBNTs fue aplicado con éxito al diagnóstico y predicción de fallos en un generador de vapor, este formalismo presenta ciertas carencias que hemos intentado superar mediante el uso de REPTDs:

- Para cada familia de nodos, una RBNT utiliza un modelo general de interacción causal. Dicho modelo presenta el inconveniente de requerir un número de parámetros que crece exponencialmente con el número de padres de la familia. Este hecho dificulta el proceso de adquisición de los parámetros y el de propagación de la evidencia en la red. La REPTD que hemos desarrollado supera

esta dificultad haciendo uso de puertas probabilistas temporales, que constituyen una adaptación de diferentes modelos canónicos de interacción causal (puerta O probabilista, puerta Y probabilista...) para procesos temporales. En las puertas probabilistas temporales, el número de parámetros necesario crece proporcionalmente con el número de padres de la familia de nodos correspondiente. Además, al contrario que en el caso del modelo de interacción general, estos nuevos modelos se acercan a la noción intuitiva humana de causalidad. Como consecuencia de lo anterior, nuestro modelo requiere menos pruebas de simulación para la obtención de las probabilidades condicionales y a priori, lo cual simplificó en gran medida el proceso de adquisición de los parámetros de la red.

- La introducción de evidencia en un nodo de una RBNT requiere conocer el tiempo de ocurrencia de ese nodo y el de uno de sus nodos padre. Si sólo se conoce el tiempo de ocurrencia del nodo hijo, hay que considerar diferentes escenarios, cada uno asociado a un padre diferente. Esto es debido a que los valores que puede tomar cualquier variable se definen mediante intervalos de tiempo relativos a la ocurrencia de sus nodos padre. Nosotros hemos superado la dificultad de la aparición de escenarios haciendo uso de tiempos absolutos en lugar de tiempos relativos. Es decir, la ocurrencia de un evento en un instante determinado constituye evidencia directa que puede ser introducida en la red, ya que cada valor que puede tomar su nodo asociado representa un tiempo absoluto en que dicho evento tiene lugar.
- La definición de los valores que puede tomar un nodo con padres de una RBNT no es lo suficientemente general, puesto que no se solapa el tiempo relativo transcurrido entre un evento padre y el evento hijo con el tiempo relativo transcurrido entre otro evento padre diferente y el mismo evento hijo. Por tanto, a pesar de que para el dominio de diagnóstico y predicción de fallos en un generador de vapor de una central termoeléctrica una RBNT ha demostrado ser un método de representación adecuado, para otros dominios más generales este formalismo no resulta apropiado. Sin embargo, el método de REPTDs no está sujeto a la restricción anterior y se puede aplicar de forma general a cualquier dominio que presente incertidumbre y esté caracterizado por la aparición de eventos temporales.



## Parte IV

# CONCLUSIONES



# Capítulo 9

## Resultados y trabajo futuro

### 9.1. Evolución de la tesis

Tal como se indicó en el capítulo 1, el objetivo inicial fijado para esta tesis doctoral consistía en la creación de un sistema que modelara la evolución de un cáncer de nasofaringe y sirviera de ayuda a los expertos médicos pertenecientes a una unidad de oncología radioterápica. El marco conceptual dentro del cual se debía llevar a cabo el desarrollo del sistema para cáncer de nasofaringe era el proyecto DIAGEN. Como línea de trabajo de este proyecto se estableció la transformación de patrones genéricos de conocimiento médico en las tareas de diagnóstico y planificación de terapia, desde su formulación en lenguaje natural hasta sus modelos en los niveles simbólico o conexionista.

Después de las primeras entrevistas con los oncólogos, llegamos a la conclusión de que había que diferenciar dos etapas en la evolución de un cáncer: la fase en que todavía no se ha aplicado ninguna terapia y la fase que sigue a la aplicación de terapia. Si bien en la primera fase entran en juego procesos irreversibles, la reversibilidad es una característica que hay que tener en cuenta en la segunda de las fases. Con el fin de hacer el estudio abordable, decidimos ceñirnos al análisis de la etapa de la enfermedad en la que aún no se ha aplicado ninguna terapia. En consecuencia, establecimos como objetivo final la elaboración de un modelo de crecimiento para cáncer de nasofaringe, que permitiera conocer la etapa de desarrollo alcanzada por el cáncer antes de elegir la terapia adecuada. La terapia que se debe aplicar está condi-

cionada precisamente por el desarrollo alcanzado por el cáncer. Por otra parte, este modelo también podría servir para dar un pronóstico de la evolución cancerígena en caso de que no le fuera aplicado ningún tratamiento al paciente.

Una vez planteado el resultado final que queríamos obtener, convenía fijar una serie de objetivos intermedios que nos fueran acercando progresivamente a nuestra meta. Seguidamente nos referimos a estos objetivos intermedios de acuerdo con los tres niveles propuestos por David Marr [89]: teoría, algoritmo e implementación.

A partir del modelado en el nivel del conocimiento realizado dentro del proyecto DIAGEN y una vez aprovechada la parte genérica del mismo para ser aplicada en nuestro dominio oncológico, necesitamos establecer qué métodos podrían permitir resolver adecuadamente las tareas específicas que aparecen en nuestro dominio. Cualquiera que fuera el formalismo finalmente elegido para abordar desde un punto de vista teórico la resolución de nuestro problema, dicho formalismo debía cumplir una serie de requisitos:

- Representar la *causalidad* propia de cualquier enfermedad oncológica.
- Tratar la *incertidumbre* inherente a este dominio médico.
- Utilizar una representación explícita del *tiempo*, que constituye una variable fundamental en cáncer.

Ninguno de los formalismos existentes satisfacía completamente los requisitos teóricos planteados a priori, debido a lo cual desarrollamos un nuevo método para razonamiento temporal con incertidumbre, que denominamos *red de eventos probabilistas en tiempo discreto*, inspirado en el formalismo de RBNT de Arroyo Figueroa y Súcar.

Todo método para la representación de conocimiento debe poseer una serie de algoritmos asociados que permitan realizar inferencias. Estos algoritmos forman la base de unos mecanismos de razonamiento que posibilitan la obtención de nuevo conocimiento. Cualquier tipo de algoritmo del que hiciéramos uso en nuestro sistema, bien reutilizado a partir de cierto formalismo bien desarrollado de forma novedosa, debería poseer una complejidad computacional que hiciera tratable el conjunto de tareas que pretendíamos resolver. Precisamente uno de los problemas que aparece generalmente al aplicar cualquier método que utilice una representación temporal es

el de la complejidad resultante del modelo. Este inconveniente surgió también en nuestro caso y obligó a que nos planteáramos un esquema alternativo para la realización de la inferencia. Dicho esquema consistió en la utilización de la factorización de las probabilidades condicionales presente en cada familia de nodos de la red de eventos, propuesta por Díez [47], lo cual proporcionó importantes ventajas en cuanto a la reducción de la complejidad del proceso inferencial. Nuestra contribución a este trabajo [49] consistió en el estudio empírico de la complejidad temporal del algoritmo desarrollado.

El trabajo llevado a cabo con los oncólogos se vio finalmente plasmado en la implementación de un sistema que sirve de ayuda a la labor médica. Dicho sistema incluye el conocimiento obtenido de los expertos médicos, las capacidades inferenciales necesarias y una interfaz que hemos pretendido sea lo más amigable posible. Una de las limitaciones de este sistema, construido mediante la introducción de tiempos absolutos en la red de eventos, es la lentitud que todavía se hace patente en el proceso inferencial. El empleo de tiempos relativos habría conducido a una red de eventos más simple; en cambio, habría sido necesario tener en cuenta diferentes escenarios en el proceso de inferencial, lo cual hace que la obtención de las probabilidades a posteriori sea una labor algo complicada. Si bien utilizamos tiempos relativos en los prototipos iniciales del sistema, finalmente decidimos incorporar tiempos absolutos al modelo (véase la sección 7.4.4).

La presente tesis doctoral, sin apartarse del camino marcado en un principio, amplió el horizonte de sus objetivos una vez vislumbrada la utilidad general que podían tener las redes de eventos que habíamos aplicado inicialmente en medicina. Los nuevos objetivos marcados nos condujeron a un dominio industrial: el modelado de fallos en un generador de vapor de una central termoeléctrica, debido a que nuestro formalismo es una modificación del de Arroyo Figueroa y Súcar.

## 9.2. Principales aportaciones

Podemos agrupar las aportaciones de la presente tesis doctoral en tres grandes apartados: aportaciones al modelado de conocimiento en DIAGEN, aportaciones al campo de las redes bayesianas temporales y, finalmente, aplicaciones.

## Modelado del conocimiento: DIAGEN

Dentro del marco metodológico desarrollado en el proyecto DIAGEN, hemos modelado la capa de conocimiento del dominio referente a las entidades y sus relaciones, haciendo uso de una **representación homogénea** que tiene en cuenta el carácter causal, incierto y temporal del dominio de cáncer de nasofaringe. Dicha homogeneidad nos ha permitido enlazar de forma directa la capa de conocimiento de tareas con el formalismo de redes bayesianas. Esta conexión la hemos realizado a través de un nuevo método para razonamiento temporal mediante redes bayesianas, que desde el punto de vista de la reutilización posee la ventaja de tener acceso a todas las capacidades que las redes bayesianas ofrecen en cuanto a representación e inferencia.

### Redes bayesianas temporales

A nuestro juicio, el formalismo de redes bayesianas resultó ser el que mejor se adaptaba a los requisitos que se presentaban en nuestro dominio, referentes a la representación de causalidad e incertidumbre. Sin embargo, en relación a la introducción de una representación explícita del tiempo en la red, ninguno de los métodos existentes para razonamiento temporal con redes bayesianas satisfacía en su totalidad los requisitos planteados. A modo de ejemplo, las *redes bayesianas dinámicas* son adecuadas para procesos markovianos en los que el estado de una variable puede cambiar repetidas veces a lo largo del tiempo. En nuestro dominio, los procesos existentes no tienen en general naturaleza markoviana y, además, son de carácter irreversible. En cuanto a las *redes bayesianas con nodos temporales*, utilizan únicamente el modelo general de interacción causal entre nodos de una familia. Este modelo no es aplicable en nuestro dominio. Además, este tipo de redes para razonamiento temporal emplea tiempos relativos respecto a los nodos padre para definir los valores de un nodo hijo, lo cual hace que el modelo pierda simplicidad y generalidad.

Nuestras aportaciones al modelado de procesos temporales mediante redes bayesianas se pueden enumerar del siguiente modo:

1. Como resultado fundamental fruto de la presente tesis doctoral, mencionamos el desarrollo del método de **red de eventos probabilistas en tiempo dis-**

**creto** (REPTD). Este tipo de redes bayesianas temporales resulta apropiado para el modelado del proceso de crecimiento de un cáncer de nasofaringe y, en general, de cualquier otro tipo de cáncer. Debido a que una REPTD incorpora variables temporales cuyo número de valores o estados puede ser alto, una limitación del nuevo método es que su complejidad computacional generalmente es alta. Además, resulta complicado modelar procesos reversibles mediante REPTDs, ya que habría que repetir cada variable un número de veces que coincide con el número de ocasiones en que puede ocurrir su tipo de evento asociado.

2. Dentro del método de REPTDs, un aspecto fundamental consistió en el establecimiento de nuevos modelos temporales de interacción causal. En el caso de redes bayesianas sin representación explícita del tiempo, estos modelos (puertas O, Y... probabilistas) se denominan *modelos canónicos*, cuyas ventajas con respecto al modelo de interacción general han sido ampliamente comentadas a lo largo de la memoria. Como novedad para el caso temporal, hemos definido nuevos modelos canónicos de interacción causal a través de las denominadas **puertas probabilistas temporales**. Estos modelos facilitan el proceso de adquisición y almacenamiento de conocimiento temporal, así como el proceso de inferencia en la red. Además, están más cercanos a la noción intuitiva de causalidad.
3. La inferencia en REPTDs queda simplificada y mejorada desde el punto de vista de la complejidad, gracias a la **factorización de puertas MAX y MIN** que describimos en la sección 5.8.1 de la memoria. Esta factorización evita tener que calcular las tablas de probabilidades condicionales asociadas a una familia de nodos que interactúan según un modelo de puerta probabilista temporal, sin tener que renunciar por ello al empleo de los algoritmos estándares para el cálculo exacto de probabilidades a posteriori en redes bayesianas. Desde el punto de vista de la complejidad, la nueva factorización supone una mejora respecto a cualquier otra factorización anterior sugerida para las puertas MAX y MIN probabilistas. Nuestra aportación en relación a la nueva factorización consistió en la colaboración con el Prof. Díez en la fase experimental del desarrollo.

## Aplicaciones

Hemos centrado nuestros esfuerzos en dos tipos de aplicaciones:

1. Otro resultado destacable del trabajo llevado a cabo en la presente tesis doctoral es el desarrollo de **NasoNet**, fruto de la aplicación del método de REPTDs al caso de cáncer de nasofaringe. NasoNet y el sistema de Cao et al. [17], son las dos únicas aplicaciones oncológicas —de las que tenemos conocimiento— que introducen una representación explícita del tiempo dentro de un marco probabilista, como son las redes bayesianas o los diagramas de influencia. A nuestro juicio, es primordial introducir una representación explícita del tiempo en cualquier dominio oncológico ya que, por un lado, el tiempo determina la etapa de desarrollo de la enfermedad y, por otro lado, el mismo tipo de eventos relacionados con el crecimiento cancerígeno puede producir diagnósticos diferentes en función de los tiempos de aparición de esos eventos. A pesar de que NasoNet se aplica a un tipo de cáncer concreto, la metodología empleada tiene carácter general y se puede aplicar de forma análoga a cualquier otro tipo de cáncer.

Hemos implementado un sistema adaptado a las necesidades de los oncólogos, que integra la red NasoNet, la utilización de las nuevas factorizaciones ya mencionadas en esta sección y una **interfaz** que permite introducir de manera amigable los hallazgos encontrados en un paciente, además de visualizar de forma gráfica o numérica los resultados de la inferencia.

2. Para demostrar la **generalidad del método de REPTDs**, lo hemos aplicado a un dominio industrial como es el diagnóstico y pronóstico de los fallos que ocurren en un generador de vapor de una central termoeléctrica. A este mismo dominio ya se había aplicado anteriormente el método de RBNTs, respecto a las cuales las REPTDs muestran ciertas ventajas basadas en su mayor simplicidad.

## Resumen

Se podrían enumerar del siguiente modo los logros alcanzados como resultado del trabajo desarrollado en la presente tesis doctoral:

- Formalización de un nuevo método para razonamiento temporal con redes bayesianas, que hemos denominado *red de eventos probabilistas en tiempo discreto*.
- Formalización de nuevos modelos canónicos temporales de interacción causal a los que hemos dado el nombre general de *puertas probabilistas temporales*.
- Aplicación de un nuevo tipo de factorización para puertas MAX y MIN probabilistas.
- Aplicación del método de REPTDs al dominio de cáncer de nasofaringe, obteniendo como resultado la red NasoNet.
- Demostración del carácter general del método de REPTDs a través de su aplicación a un dominio industrial.

### 9.3. Futuras líneas de investigación

Los resultados del trabajo realizado en la presente tesis doctoral, han abierto nuevos horizontes en relación a la exploración de nuevas materias de interés. Las líneas de investigación abiertas que mencionamos seguidamente tienen la suficiente relevancia como para merecer un estudio profundo en el futuro.

#### Representación de conocimiento

En relación al campo de la representación de conocimiento, se pueden realizar las siguientes consideraciones:

1. A lo largo de la presente memoria hemos descrito la aplicación del método de REPTDs a procesos de carácter irreversible. En procesos de carácter reversible, el mismo tipo de evento puede ocurrir en dos o más tiempos diferentes. Queda por analizar cómo habría que ampliar el método de REPTDs para poder tratar de forma eficiente el caso de **procesos reversibles**. Una vez resuelta esta cuestión, el nuevo método podría ser aplicado al modelado de la evolución de un cáncer en la fase de tratamiento, en la cual la enfermedad puede avanzar y retroceder repetidas veces.

2. En nuestro trabajo hemos considerado exclusivamente eventos consistentes en la aparición de una determinada anomalía. Por otra parte, en el caso de variables graduadas (véase la sección 4.1.2) podría existir **una serie de eventos asociados a una misma variable**. Cada posible evento estaría relacionado con la adopción de uno de los valores que puede tomar la variable graduada. Las REPTDs podrían ser extendidas tomando en consideración el caso anterior, donde varios cambios de estado diferentes se pueden producir en una misma variable.
3. Los mismos pasos que hemos seguido para la definición de una REPTD, conducirían de forma análoga al establecimiento de un nuevo método para **razonamiento espacial** mediante redes bayesianas. Si en el caso temporal se discretiza el tiempo perteneciente a un determinado rango, en el caso espacial se discretizaría una determinada parte unidimensional, bidimensional o tridimensional del espacio. Si en el caso temporal cada variable representa un evento, en el caso espacial representaría un objeto. Finalmente, si en el caso espacial cada valor de una variable está asociado a la aparición de un evento en un determinado tiempo, en el caso espacial cada valor estaría asociado a la localización de un objeto en un determinado punto.

### Algoritmos más eficientes

La inferencia exacta en REPTDs queda facilitada en gran medida por la utilización de la factorización para puertas MAX y MIN que hemos estudiado en la sección 5.8.1. Los métodos aproximados de propagación constituyen la única opción válida para la realización de inferencia en REPTDs de gran complejidad estructural y con un alto número de valores en sus variables. Resultaría de interés la realización de un estudio de qué métodos aproximados de inferencia son viables en presencia de puertas probabilistas temporales en la red, en las cuales resulta problemático e ineficiente el desarrollo completo de sus tablas de probabilidades condicionales. Algunas posibilidades son las siguientes:

1. El Prof. Antonio Salmerón, de la Universidad de Almería, sugirió en la reunión del proyecto Elvira que tuvo lugar en Albacete en junio de 2002 la utilización de **árboles de probabilidad** [10, 16, 116] para la representación de modelos

canónicos. Resultaría de interés estudiar, por un lado, la utilización de árboles de probabilidad en REPTDs y, por otro lado, la aplicación de árboles de probabilidad como método aproximado determinista para la realización de inferencia en REPTDs. El uso de árboles de probabilidad como método aproximado de inferencia se basa en la realización de podas en el árbol. A nuestro juicio, estas podas estarían más que justificadas en una REPTD, donde muchos de los parámetros probabilísticos que la definen son nulos.

2. La mayoría de los métodos de simulación estocástica mencionados en la sección 4.1.1 pueden ser considerados como casos particulares del método de **muestreo por importancia** (consúltese [27]). Uno de los principales factores para que el método de muestreo por importancia converja lo más rápidamente posible es hallar una función de importancia para cada variable, que sea lo más parecida posible a la distribución de probabilidades a posteriori que se pretende calcular. Se podría investigar la realización de inferencia en REPTDs dentro del marco de muestreo por importancia. Para el cálculo de las funciones de importancia, mencionamos dos posibilidades:
  - Utilizar un algoritmo exacto, como puede ser el de eliminación de variables, en una red con árboles de probabilidad podados, que antes de ser podados se utilizaban para la representación de modelos canónicos, según la propuesta del Prof. Salmerón.
  - Utilizar un algoritmo exacto en una red con árboles de probabilidad podados, que antes de ser podados se utilizaban para la representación de los potenciales o parámetros pertenecientes a una red con familias factorizadas mediante el método propuesto por el Prof. Díez.

## Aplicaciones

Quedan abiertas las siguientes líneas de investigación en relación a las aplicaciones médicas e industriales creadas:

1. La **interfaz de NasoNet** puede ser mejorada en ciertos aspectos. Uno de ellos es la selección automática, dada cierta evidencia, de los eventos más probables y, por tanto, de más interés para el oncólogo. En la actualidad, esta tarea no

ha podido ser implementada debido a problemas de eficiencia computacional. También sería conveniente diseñar en la interfaz la capacidad de poder fijar la visualización de las probabilidades a posteriori de los eventos de la red en función de un trimestre seleccionado por el usuario. De este modo, se podrían consultar las probabilidades a posteriori no sólo en función de qué variable elige el usuario sino del período en que está más interesado. Por otra parte, convendría analizar con detenimiento qué utilidades adicionales se podrían incorporar a la interfaz para hacerla más completa.

2. Una vez realizada una evaluación más exhaustiva de NasoNet a partir de casos reales futuros, que permitiera la depuración del sistema, la experiencia acumulada con NasoNet podría resultar de gran ayuda en la construcción de **sistemas análogos para cánceres con más incidencia** que el de nasofaringe. Especial interés pueden tener redes para cáncer de pulmón, laringe o mama, entre otros.
3. Queda por completar la **evaluación y depuración del sistema que hemos construido para el diagnóstico y predicción de fallos en un generador de vapor de una central termoeléctrica**. Esperamos poder realizar tal labor a partir del mismo conjunto de datos que los Profs. Arroyo Figueroa y Súcar utilizaron para la evaluación de su red bayesiana con nodos temporales, que aplicaron a este mismo dominio con anterioridad a nuestro trabajo.
4. El carácter general de las REPTDs hace que puedan tener **aplicación en un amplio abanico de dominios**, además de la medicina y la industria. Particular interés tendría la aplicación a razonamiento espacial en robótica de un enfoque como el sugerido en esta misma sección para razonamiento espacial con redes bayesianas.

## Resumen

A continuación enumeramos las líneas de investigación que hemos sugerido para el futuro:

- Ampliación del método de REPTDs de manera que sea posible el tratamiento de procesos reversibles.

- 
- Aplicación del método ampliado anterior al modelado de la evolución de un cáncer en la fase de tratamiento.
  - Extensión del método de REPTDs al caso de eventos considerados a partir de variables graduadas.
  - Establecimiento de un nuevo método para razonamiento espacial con redes bayesianas, análogo al método para razonamiento temporal desarrollado en esta tesis.
  - Desarrollo de nuevos algoritmos para la propagación aproximada de la evidencia en REPTDs.
  - Mejora de la interfaz actual de NasoNet.
  - Evaluación exhaustiva de NasoNet con casos reales futuros.
  - Desarrollo de sistemas análogos a NasoNet para otros tipos de cáncer.
  - Evaluación y depuración de nuestro sistema para diagnóstico y predicción de fallos en un generador de vapor.
  - Búsqueda de nuevos dominios de aplicación para el método de REPTDs.



# Bibliografía

- [1] C. F. Aliferis y G. F. Cooper. A new formalism for temporal modeling in medical decision-support systems. En: *Proceedings of the 19th Annual Symposium on Computer Applications in Medical Care (SCAMC'95)*, págs. 213–217, Nueva Orleáns, LA, 1995. Hanley & Belfus.
- [2] C. F. Aliferis y G. F. Cooper. A structurally and temporally extended Bayesian belief network model: definitions, properties, and modeling techniques. En: *Proceedings of the 12th Conference on Uncertainty in Artificial Intelligence (UAI'96)*, págs. 28–39, Portland, OR, 1996. Morgan Kaufmann, San Francisco, CA.
- [3] J. F. Allen. Maintaining knowledge about temporal intervals. *Communications of the ACM*, **26**:832–843, 1983.
- [4] S. Andreassen, R. Hovorka, J. Benn, K. G. Olesen y E. R. Carson. A model-based approach to insulin adjustment. En: *Proceedings of the Third Conference on Artificial Intelligence in Medicine*, págs. 239–248, Maastricht, Holanda, 1991. Springer-Verlag.
- [5] G. Arroyo Figueroa. *Razonamiento Probabilístico con Nodos Temporales y su Aplicación al Diagnóstico y Predicción de Eventos*. Tesis doctoral, Instituto Tecnológico y de Estudios Superiores de Monterrey, Cuernavaca, México, 1999.
- [6] G. Arroyo Figueroa y L. E. Súcar. A temporal Bayesian network for diagnosis and prediction. En: *Proceedings of the 15th Conference on Uncertainty in Artificial Intelligence (UAI'99)*, págs. 13–20, Estocolmo, 1999. Morgan Kaufmann, San Francisco, CA.

- [7] G. Arroyo Figueroa, L. E. Súcar y A. Villavicencio. Probabilistic temporal reasoning and its application to fossil power plant operation. *Expert Systems with Applications*, **15**:317–324, 1998.
- [8] C. Berzuini. Representing time in causal probabilistic networks. En: M. Henrion, R. D. Shachter, L. N. Kanal y J. F. Lemmer (eds.), *Uncertainty in Artificial Intelligence 5*, págs. 15–28. Elsevier Science Publishers, Amsterdam, 1990.
- [9] J. Binder, K. Murphy y S. Russell. Space-efficient inference in dynamic probabilistic networks. En: *Proceedings of the 15th International Joint Conference on Artificial Intelligence (IJCAI'97)*, págs. 1292–1296, Nagoya, Japón, 1997.
- [10] J. Bouillier, N. Friedman, M. Goldszmidt y D. Koller. Context-specific independence in Bayesian networks. En: *Proceedings of the 12th Conference on Uncertainty in Artificial Intelligence (UAI'96)*, págs. 115–123, Portland, OR, 1996. Morgan Kaufmann, San Francisco, CA.
- [11] F. M. T. Brazier, B. M. Dunin-Keplicz, N. R. Jennings y J. Treur. DESIRE: modelling multi-agent systems in a compositional formal framework. *International Journal of Cooperative Information Systems*, **6**:67–94, 1997.
- [12] J. Breuker y W. Van de Velde. *CommonKADS Library for Expertise Modelling. Reusable Problem-Solving Components*. IOS Press, 1994.
- [13] J. A. Breuker y B. J. Wielinga. Model driven knowledge acquisition. En: P. Guida y G. Tasso (eds.), *Topics in the Design of Expert Systems*, págs. 265–296. North Holland, Amsterdam, 1989.
- [14] D. G. Brobrow y T. Winograd. An overview of KRL, a knowledge representation language. *Cognitive Science*, **1**:3–46, 1977.
- [15] B. G. Buchanan y E. H. Shortliffe. *Rule-based expert systems: The MYCIN experiments of the Stanford Heuristic Programming Project*. Addison-Wesley, Reading, MA, 1984.
- [16] A. Cano y S. Moral. Propagación exacta y aproximada con árboles de probabilidad. En: *Actas de la VII Conferencia de la Asociación Española para la*

- Inteligencia Artificial (CAEPIA '1997)*, págs. 635–644, Torremolinos, España, 1997.
- [17] C. Cao, T. Leong, A. Leong y F. Seow. Dynamic decision analysis in medicine: a data driven approach. *International Journal of Medical Informatics*, **51**:13–28, 1998.
- [18] E. Castillo, J. M. Gutiérrez y A. S. Hadi. *Expert Systems and Probabilistic Network Models*. Springer-Verlag, Nueva York, 1997. Versión española: *Sistemas Expertos y Modelos de Redes Probabilísticas*, Academia de Ingeniería, Madrid, 1997.
- [19] B. Chandrasekaran. Towards a taxonomy of problem solving types. *Artificial Intelligence Magazine*, **4**:9–17, 1983.
- [20] B. Chandrasekaran. Generic tasks in knowledge-based reasoning: High-level building blocks for expert system design. *IEEE Expert*, **1**:23–30, 1986.
- [21] B. Chandrasekaran. Towards a functional architecture for intelligence based on generic information processing tasks. En: *Proceedings of the 7th International Joint Conference on Artificial Intelligence (IJCAI'87)*, págs. 1183–1192, Milán, Italia, 1987.
- [22] B. Chandrasekaran. Generic tasks as building blocks for knowledge-based systems: The diagnosis and routine design examples. *The Knowledge Engineering Review*, **3**:183–210, 1988.
- [23] B. Chandrasekaran, T. R. Johnson y J. W. Smith. Task-structure analysis for knowledge modeling. *Communications of the ACM*, **35**:124–137, 1992.
- [24] B. Chandrasekaran, J. R. Josephson y R. Benjamins. The ontology of tasks and methods. En: *Proceedings of the 11th Workshop on Knowledge Acquisition, Modeling and Management (KAW'98)*, Banff, Alberta, Canadá, 1998.
- [25] S. Chatel y F. Détienne. Strategies in object-oriented design. *Acta Psychologica*, **91**:245–269, 1996.
- [26] V. K. Chaudhri, A. Farquhar, R. Fikes, P. D. Karp y J. P. Rice. OKBC: A programmatic foundation for knowledge base interoperability. En: *Proceedings*

- of the 15th National Conference of Artificial Intelligence (AAAI'98), Madison, WI, 1998. AAAI Press/The MIT Press.
- [27] J. Cheng y M. J. Druzdzel. AIS-BN: an adaptive importance sampling algorithm for evidential reasoning in large Bayesian networks. *Journal of Artificial Intelligence Research*, **13**:155–188, 2000.
- [28] W. J. Clancey. Tutoring rules for guiding a case method dialogue. *International Journal of Man-Machine Studies*, **11**:25–49, 1979.
- [29] W. J. Clancey. The epistemology of a rule-based system: A framework for explanation. *Artificial Intelligence*, **20**:215–251, 1983.
- [30] W. J. Clancey. Heuristic Classification. *Artificial Intelligence*, **27**:289–350, 1985.
- [31] W. J. Clancey. Notes on “Heuristic classification”. *Artificial Intelligence*, **59**:191–196, 1993.
- [32] P. Coad. *Object-Oriented Analysis*. Prentice-Hall, Englewood Cliffs, NJ, 1991. Segunda edición.
- [33] N. Cocchiarella. *Tense and Modal Logic: A Study in the Topology of Temporal Reference*. Tesis doctoral, UCLA, Los Angeles, CA, 1965.
- [34] C. L. Corritore y S. Wiedenbeck. Mental representations of expert procedural and object-oriented programmers in a software maintenance task. *International Journal of Human-Computer Studies*, **50**:61–83, 1998.
- [35] D. R. Cox y D. Oakes. *Analysis of Survival Data*. Chapman and Hall, 1984.
- [36] F. G. Cozman. Generalizing variable elimination in Bayesian networks. En: *Proceedings of the IBERAMIA/SBIA 2000 Workshop on Probabilistic Reasoning in Artificial Intelligence*, págs. 27–32, São Paulo, Brasil, 2000.
- [37] P. Dagum y A. Galper. Forecasting sleep apnea with dynamic network models. En: *Proceedings of the 9th Conference on Uncertainty in Artificial Intelligence (UAI'93)*, págs. 64–71, Washington D.C., 1993. Morgan Kaufmann, San Francisco, CA.

- [38] P. Dagum, A. Galper y E. Horvitz. Dynamic network models for forecasting. En: *Proceedings of the 8th Conference on Uncertainty in Artificial Intelligence (UAI'92)*, págs. 41–48, Stanford University, CA, 1992. Morgan Kaufmann, San Francisco, CA.
- [39] A. Davidson. A survey of logic programming-based object-oriented languages. En: G. Agha, P. Wegner y A. Yonezawa (eds.), *Research Directions in Concurrent Object-Oriented Programming*, págs. 42–106. MIT Press, Londres, 1993.
- [40] T. Dean y K. Kanazawa. A model for reasoning about persistence and causation. *Computational Intelligence*, **5**:142–150, 1989.
- [41] R. Dechter. From local to global consistency. *Artificial Intelligence*, **55**:87–107, 1992.
- [42] R. Dechter. Bucket elimination: a unifying framework for probabilistic inference. En: *Proceedings of the 12th Conference on Uncertainty in Artificial Intelligence (UAI'96)*, págs. 211–219, Portland, OR, 1996. Morgan Kaufmann, San Francisco, CA.
- [43] R. Dechter, I. Meiri y J. Pearl. Temporal constraints networks. *Artificial Intelligence*, **49**:61–95, 1991.
- [44] R. Dechter y J. Pearl. Network-based heuristics for constraint-satisfaction problems. *Artificial Intelligence*, **34**:1–38, 1988.
- [45] F. J. Díez. Parameter adjustment in Bayes networks. The generalized noisy OR-gate. En: *Proceedings of the 9th Conference on Uncertainty in Artificial Intelligence (UAI'93)*, págs. 99–105, Washington D.C., 1993. Morgan Kaufmann, San Francisco, CA.
- [46] F. J. Díez. Local conditioning in Bayesian networks. *Artificial Intelligence*, **87**:1–20, 1996.
- [47] F. J. Díez. Efficient computation for the noisy MAX. En: *Actas de la IX Conferencia de la Asociación Española para la Inteligencia Artificial (CAE-PIA'2001)*, págs. 1115–1124, Gijón, España, 2001.

- [48] F. J. Díez y M. Druzdzel. Canonical probabilistic models for knowledge engineering. Informe técnico, Dpto. de Inteligencia Artificial, UNED, Madrid, 2002. En preparación.
- [49] F. J. Díez y S. F. Galán. Efficient computation for the noisy MAX. *International Journal of Intelligent Systems*, 2002. En imprenta.
- [50] D. Fensel y R. Benjamins. Key issues for automated problem-solving methods reuse. En: *Proceedings of the 13th European Conference on Artificial Intelligence (ECAI'98)*, págs. 63–67, Brighton, Reino Unido, 1998. John Wiley & Sons.
- [51] D. Fensel, V. R. Benjamins, E. Motta y B. J. Wielinga. UPML: A framework for knowledge system reuse. En: *Proceedings of the 16th International Joint Conference on Artificial Intelligence (IJCAI'99)*, págs. 16–23, Estocolmo, 1999.
- [52] D. Fensel y F. van Harmelen. A comparison of languages which operationalise and formalise KADS models of expertise. *Knowledge Engineering Review*, 9:105–146, 1994.
- [53] R. Fikes y T. Kehler. The role of frame-based representation in reasoning. *Communications of the ACM*, 28:904–920, 1985.
- [54] M. Fowler. *Analysis Patterns: Reusable Object Models*. Addison-Wesley, Reading, MA, 1996.
- [55] R. Fung y K. Chang. Weighing and integrating evidence for stochastic simulation in Bayesian networks. En: M. Henrion, R. D. Shachter, L. N. Kanal y J. F. Lemmer (eds.), *Uncertainty in Artificial Intelligence 5*, págs. 209–219. Elsevier Science Publishers, Amsterdam, 1990.
- [56] R. Fung y B. D. del Favero. Backward simulation in Bayesian networks. En: *Proceedings of the 10th Conference on Uncertainty in Artificial Intelligence (UAI'94)*, págs. 227–234, Seattle, WA, 1994. Morgan Kaufmann, San Francisco, CA.

- [57] S. F. Galán, F. Aguado, F. J. Díez y J. Mira. NasoNet, joining Bayesian networks and time to model nasopharyngeal cancer spread. En: *Proceedings of the 8th European Conference on Artificial Intelligence in Medicine (AIME'01)*, págs. 207–216, Cascais, Portugal, 2001. Springer.
- [58] S. F. Galán, F. Aguado, F. J. Díez y J. Mira. NasoNet, modeling the spread of nasopharyngeal cancer with networks of probabilistic events in discrete time. *Artificial Intelligence in Medicine*, **25**:247–264, 2002.
- [59] S. F. Galán y F. J. Díez. Networks of probabilistic events in discrete time. *International Journal of Approximate Reasoning*, **30**:181–202, 2002.
- [60] E. Gamma, R. Helm, R. Johnson y J. Vlissides. *Design Patterns. Elements of Reusable Object-Oriented Software*. Addison-Wesley, Reading, MA, 1995.
- [61] A. Ginsberg. Knowledge-based reduction: a new approach to checking knowledge bases for inconsistency and redundancy. En: *Proceedings of the 7th National Conference on Artificial Intelligence (AAAI'88)*, págs. 585–589, Saint Paul, MI, 1988.
- [62] T. R. Gruber. A translation approach to portable ontology specifications. *Knowledge Acquisition*, **5**:199–220, 1993.
- [63] P. Haddawy, J. W. Helwig, L. Ngo, M. S. Robert y A. Krieger. Clinical simulation using context-sensitive temporal probability models. En: *Proceedings of the 19th Annual Symposium on Computer Applications in Medical Care (SCAMC'95)*, págs. 203–207, Nueva Orleans, LA, 1995. Hanley & Belfus.
- [64] F. Hayes-Roth, D. Waterman y D. Lenat. *Building Expert Systems*. Addison-Wesley, 1983.
- [65] D. E. Heckerman, E. J. Horvitz y B. N. Nathwani. Toward normative expert systems: Part I — The Pathfinder Project. *Methods of Information in Medicine*, **31**:90–105, 1992.
- [66] D. E. Heckerman y B. N. Nathwani. Toward normative expert systems: Part II — Probability-based representations for efficient knowledge acquisition and inference. *Methods of Information in Medicine*, **31**:106–116, 1992.

- [67] M. Henrion. Propagation of uncertainty by logic sampling in Bayes' networks. En: J. F. Lemmer y L. N. Kanal (eds.), *Uncertainty in Artificial Intelligence 2*, págs. 149–164. Elsevier Science Publishers, Amsterdam, 1988.
- [68] M. Henrion. Some practical issues in constructing belief networks. En: L. N. Kanal, T. S. Levitt y J. F. Lemmer (eds.), *Uncertainty in Artificial Intelligence 3*, págs. 161–173. Elsevier Science Publishers, Amsterdam, 1989.
- [69] M. E. Hernando, E. J. Gómez, F. del Pozo y R. Corcoy. DIABNET: A qualitative model-based advisory system for therapy planning in gestational diabetes. *Medical Informatics*, **21**:359–374, 1996.
- [70] F. V. Jensen, K. G. Olesen y S. K. Andersen. An algebra of Bayesian belief universes for knowledge-based systems. *Networks*, **20**:637–660, 1990.
- [71] C. E. Kahn, L. M. Roberts, K. A. Shaffer y P. Haddawy. Construction of a Bayesian network for mammographic diagnosis of breast cancer. *Computers in Biology and Medicine*, **27**:19–29, 1997.
- [72] K. Kanazawa. *Reasoning about Time and Probability*. Tesis doctoral, Department of Computer Science, Brown University, 1992.
- [73] J. H. Kim. *CONVINCE: A Conversation Inference Consolidation Engine*. Tesis doctoral, Department of Computer Science, UCLA, Los Angeles, CA, 1983.
- [74] U. Kjærulff. A computational scheme for reasoning in dynamic probabilistic networks. En: *Proceedings of the 8th Conference on Uncertainty in Artificial Intelligence (UAI'92)*, págs. 121–129, Stanford University, CA, 1992. Morgan Kaufmann, San Francisco, CA.
- [75] S. Kripke. Semantical considerations on modal logic. *Acta Philosophica Fennica*, **16**:83–94, 1963.
- [76] C. Lacave. *Explicación en Redes Bayesianas Causales. Aplicaciones Médicas*. Tesis doctoral, Dpto. de Inteligencia Artificial, UNED, Madrid, 2002.
- [77] C. Lacave, R. Atienza y F. J. Díez. Graphical explanations in Bayesian networks. En: *Proceedings of the First International Symposium on Medical Data*

- Analysis (ISMDA-2000)*, págs. 122–129, Frankfurt, Alemania, 2000. Springer, Heidelberg.
- [78] C. Lacave y F. J. Díez. A review of explanation methods for Bayesian networks. *Knowledge Engineering Review*, 2002. En imprenta.
- [79] C. Lacave, A. Oniško y F. J. Díez. Debugging medical Bayesian networks with Elvira's explanation facility. En: *Working Notes of the AIME'01 Workshop on Bayesian Models in Medicine*, págs. 47–51, Cascais, Portugal, 2001.
- [80] D. Landes. Designkarl - a language for the design of knowledge-based systems. En: *Proceedings of the 6th International Conference on Software Engineering and Knowledge Engineering (SEKE'94)*, págs. 78–85, Jurmala, Letonia, 1994.
- [81] S. L. Lauritzen y D. J. Spiegelhalter. Local computations with probabilities on graphical structures and their application to expert systems. *Journal of the Royal Statistical Society, Series B*, **50**:157–224, 1988.
- [82] A. Lee, W. Foo, S. Law, Y. F. Poon, S. K. O, S. Y. Tung, W. M. Sze, R. Chappell, W. H. Lau y J. Ho. Staging of nasopharyngeal carcinoma: From Ho's to the new UICC system. *International Journal of Cancer*, **84**:179–187, 1999.
- [83] A. Lee y N. Pennington. The effects of paradigm on cognitive activities in design. *International Journal of Human-Computer Studies*, **40**:577–601, 1994.
- [84] T. Leong. Multiple perspective dynamic decision making. *Artificial Intelligence*, **105**:209–261, 1998.
- [85] Z. Li y B. D'Ambrosio. Efficient inference in Bayes nets as a combinatorial optimization problem. *International Journal of Approximate Reasoning*, **11**:55–81, 1994.
- [86] A. L. Madsen y B. D'Ambrosio. A factorized representation of independence of causal influence and lazy propagation. *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, **8**:151–165, 2000.
- [87] P. Magni y R. Bellazzi. DT-Planner: An environment for managing dynamic decision problems. *Computer Methods and Programs in Biomedicine*, **54**:183–200, 1997.

- [88] A. Manjarrés. *Modelos Computacionales de la Decisión Cooperativa: Perspectivas Simbólica y Conexionista*. Tesis doctoral, Dpto. de Inteligencia Artificial, UNED, Madrid, 2000.
- [89] D. Marr. *Vision*. Freeman, Nueva York, 1982.
- [90] J. McCarthy y P. Hayes. Some philosophical problems from the standpoint of artificial intelligence. En: B. Meltzer y D. Michie (eds.), *Machine Intelligence*. American Elsevier, 1969.
- [91] D. V. McDermott. A temporal logic for reasoning about processes and plans. *Cognitive Science*, **6**:101–155, 1982.
- [92] J. McDermott. Preliminary steps toward a taxonomy of problem solving-methods. En: S. Marcus (ed.), *Automating Knowledge Acquisition for Expert Systems*, págs. 225–256. Kluwer, 1988.
- [93] P. Meseguer y A. Preece. Assessing the role of formal specifications in verification and validation of knowledge-based systems. En: *Proceedings of the 3rd IFIP International Conference on “Achieving Quality in Software” (AQuIS’96)*, págs. 317–328, Florencia, Italia, 1996. Chapman and Hall.
- [94] L. A. Miller. Dynamic testing of knowledge bases using the heuristic testing approach. *Expert Systems with Applications*, **1**:249–269, 1990.
- [95] M. Minsky. A framework for representing knowledge. En: P. H. Winston (ed.), *The Psychology of Computer Vision*, págs. 211–277. McGraw-Hill, Nueva York, 1975.
- [96] M. Minsky. *The Society of Mind*. Simon and Schuster, Nueva York, 1986.
- [97] U. Montanari. Networks of constraints: fundamental properties and applications to picture processing. *Information Science*, **7**:95–132, 1974.
- [98] R. E. Neapolitan. *Probabilistic Reasoning in Expert Systems: Theory and Algorithms*. Wiley-Interscience, Nueva York, 1990.
- [99] A. Newell. The knowledge level. *Artificial Intelligence*, **18**:87–127, 1982.

- [100] L. Ngo, P. Hadawy y J. Helwig. A theoretical framework for context-sensitive temporal probability model construction with application to plan projection. En: *Proceedings of the 11th Conference on Uncertainty in Artificial Intelligence (UAI'95)*, págs. 419–426, Montreal, Canadá, 1995. Morgan Kaufmann, San Francisco, CA.
- [101] A. E. Nicholson y J. M. Brady. Sensor validation using dynamic belief networks. En: *Proceedings of the 8th Conference on Uncertainty in Artificial Intelligence (UAI'92)*, págs. 207–214, Stanford University, CA, 1992. Morgan Kaufmann, San Francisco, CA.
- [102] J. Pearl. Reverend Bayes on inference engines: A distributed approach. En: *Proceedings of the 2nd National Conference on AI (AAAI'82)*, págs. 133–136, Pittsburgh, PA, 1982.
- [103] J. Pearl. A constraint-propagation approach to probabilistic reasoning. En: L. N. Kanal y J. F. Lemmer (eds.), *Uncertainty in Artificial Intelligence*, págs. 357–370. Elsevier Science Publishers, Amsterdam, 1986.
- [104] J. Pearl. Fusion, propagation and structuring in belief networks. *Artificial Intelligence*, **29**:241–288, 1986.
- [105] J. Pearl. Evidential reasoning using stochastic simulation of causal models. *Artificial Intelligence*, **32**:245–257, 1987.
- [106] J. Pearl. *Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference*. Morgan Kaufmann, San Francisco, CA, 1988. Reimpreso con correcciones en 1991.
- [107] M. A. Peot y R. D. Shachter. Fusion and propagation with multiple observations in belief networks. *Artificial Intelligence*, **48**:299–318, 1991.
- [108] A. Preece, R. Shinghal y A. Batarekh. Principles and practice in verifying rule-based systems. *Knowledge Engineering Review*, **7**:115–141, 1992.
- [109] G. M. Provan y J. R. Clarke. Dynamic network construction and updating techniques for the diagnosis of acute abdominal pain. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **15**:299–307, 1993.

- [110] A. R. Puerta, J. Egar, S. Tu y M. A. Musen. A multiple-method shell for the automatic generation of knowledge acquisition tools. *Knowledge Acquisition*, **4**:171–196, 1992.
- [111] M. Ramoni, M. Stefanelli, G. Barosi y L. Magnani. An epistemological framework for medical knowledge-based systems. *IEEE Transactions on Systems, Man, and Cybernetics*, **22**:1361–1375, 1992.
- [112] N. Rescher y A. Urquhart. *Temporal Logic*. Springer-Verlag, Nueva York, 1971.
- [113] R. B. Roberts y I. P. Goldstein. *The FRL Primer*. Artificial Intelligence Laboratory, MIT, Cambridge, MA, 1977.
- [114] M. B. Rosson y S. R. Alpert. The cognitive consequences of object oriented design. *Human-Computer Interaction*, **5**:345–379, 1990.
- [115] J. Rumbaugh, M. Blaha, W. Premerlani, F. Eddy y W. Lorensen. *Object-Oriented Modeling and Design*. Prentice-Hall, Englewood Cliffs, NJ, 1991.
- [116] A. Salmerón, A. Cano y S. Moral. Importance sampling in Bayesian networks using probability trees. *Computational Statistics and Data Analysis*, **34**:387–413, 2000.
- [117] E. Santos y J. D. Young. Probabilistic temporal networks: A qualitative unified framework for reasoning with time and uncertainty. *International Journal of Approximate Reasoning*, **20**:263–291, 1999.
- [118] S. P. Schantz, L. B. Harrison y A. A. Forastiere. Tumors of the nasal cavity and paranasal sinuses, nasopharynx, oral cavity, and oropharynx. En: V. T. DeVita, S. Hellman y S. A. Rosenberg (eds.), *Cancer: Principles and Practice of Oncology*, págs. 741–801. Lippincott-Raven Publishers, Philadelphia, PA, 1997.
- [119] A. Th. Schreiber, B. J. Wielinga, J. M. Akkermans, W. van de Velde y R. de Hoog. CommonKADS: A comprehensive methodology for KBS development. *IEEE Expert*, **9**:28–37, 1994.

- [120] G. Schreiber, B. J. Wielinga, H. Akkermans, W. van de Velde y A. Anjewierden. CML: The CommonKADS conceptual modelling language. En: *Proceedings of the 8th European Knowledge Acquisition Workshop (EKAW'94)*, págs. 1–25, Hoegaarden, Bélgica, 1994. Springer.
- [121] R. Shachter y M. Peot. Simulation approaches to general probabilistic inference on belief networks. En: M. Henrion, R. D. Shachter, L. N. Kanal y J. F. Lemmer (eds.), *Uncertainty in Artificial Intelligence 5*, págs. 221–231. Elsevier Science Publishers, Amsterdam, 1990.
- [122] R. D. Shachter, B. D'Ambrosio y B. A. del Favero. Symbolic probabilistic inference in belief networks. En: *Proceedings of the 8th National Conference on Artificial Intelligence (AAAI'90)*, págs. 126–131, Boston, MA, 1990.
- [123] P. P. Shenoy y G. Shafer. Axioms for probability and belief-function propagation. En: R. D. Shachter, T. S. Levitt, L. N. Kanal y J. F. Lemmer (eds.), *Uncertainty in Artificial Intelligence 4*, págs. 169–198. Elsevier Science Publishers, Amsterdam, 1990.
- [124] E. H. Shortliffe. On the MYCIN system. Informe técnico 84-095, SMI, Stanford University, CA, 1984.
- [125] L. Steels. Components of expertise. *Artificial Intelligence Magazine*, **11**:29–49, 1990.
- [126] M. Takikawa y B. D'Ambrosio. Multiplicative factorization of noisy-MAX. En: *Proceedings of the 15th Conference on Uncertainty in Artificial Intelligence (UAI'99)*, págs. 622–630, Estocolmo, 1999. Morgan Kaufmann, San Francisco, CA.
- [127] D. S. W. Tansley y C. C. Hayball. *Knowledge-Based Systems Analysis and Design: A KADS Developer's Handbook*. Prentice-Hall, 1993.
- [128] J. A. Tatman y R. D. Shachter. Dynamic programming and influence diagrams. *IEEE Transactions on Systems, Man, and Cybernetics*, **20**:365–379, 1990.
- [129] A. Tavira y R. Berdón. Simulador de la central termoeléctrica Manzanillo II. Informe Técnico 19018, Instituto de Investigaciones Eléctricas, México, 1992.

- [130] A. Y. Tawfik y E. Neufeld. Temporal reasoning and Bayesian networks. *Computational Intelligence*, **16**:349–377, 2000.
- [131] W. van de Velde. A constructivist view on knowledge engineering. En: *Proceedings of the 11th European Conference on Artificial Intelligence (ECAI'94)*, págs. 727–731, Amsterdam, Holanda, 1994. John Willey & Sons.
- [132] F. van Harmelen y J. Balder. (ML)<sup>2</sup>: A formal language for KADS model of expertise. *Knowledge Acquisition*, **4**:127–161, 1992.
- [133] G. van Heijst, S. Falasconi, A. Abu-Hanna, G. Schreiber y M. Stefanelli. A case study in ontology library construction. *Artificial Intelligence in Medicine*, **7**:227–255, 1995.
- [134] W. van Melle, E. H. Shortliffe y B. G. Buchanan. EMYCIN: A knowledge engineer's tool for constructing rule-based expert systems. En: B. G. Buchanan y E. H. Shortliffe (eds.), *Rule-Based Expert Systems: The MYCIN Experiments of the Stanford Heuristic Programming Project*, págs. 302–313. Addison-Wesley, 1984.
- [135] B. J. Wielinga, A. Th. Schreiber y J. A. Breuker. KADS: A modelling approach to knowledge engineering. *Knowledge Acquisition*, **4**:5–54, 1992.
- [136] N. L. Zhang y L. Yan. Independence of causal influence and clique tree propagation. *International Journal of Approximate Reasoning*, **19**:335–349, 1997.