

*Aplicación de  
Redes Bayesianas Temporales  
al Diagnóstico y Predicción de Fallos  
en Generadores de Vapor*

Severino Fernández Galán  
<http://www.ia.uned.es/~seve/>  
Departamento de Inteligencia Artificial  
Universidad Nacional de Educación a Distancia (UNED), España

*Aplicación de RBTs al Diagnóstico y Predicción de Fallos en Generadores de Vapor*

**RESUMEN**

- **Definición de los objetivos del sistema**
- **Análisis de las características principales del dominio**
- **Elección del método de representación de conocimiento adecuado**
- **Descripción del diseño e implementación del sistema**
- **Ejemplo de aplicación**
- **Conclusiones**

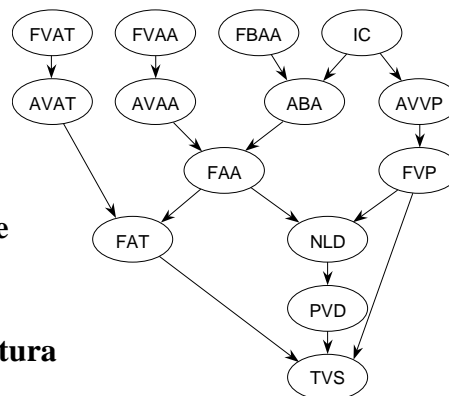
## OBJETIVOS DEL SISTEMA

- **Modelar el proceso general de propagación de fallos en un generador de vapor de una central termoeléctrica**
- **Ayudar a los técnicos de la central en el diagnóstico y predicción de dichos fallos, producidos a partir de una perturbación inicial en el generador**

## CAUSALIDAD

- **Proceso de propagación de fallos: secuencia de eventos temporales causalmente interrelacionados**

- **Eventos iniciales:** fallo en válvulas o bombas
- **Eventos intermedios:** apertura de válvulas, aceleración en bombas, incremento en los flujos de agua o vapor...
- **Evento final:** decremento en la temperatura del vapor sobrecalentado



## INCERTIDUMBRE

- **Fuente de incertidumbre: en cada arco el retardo temporal entre causa y efecto no es constante**

**FBAA → ABA**

10	10	10	10	11	11	11	11	12	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	20	21	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	29	31	31	
31	31	32	32	32	32																		

## TIEMPO


- **En general, la relación causal entre un par de eventos no es instantánea:**

**FBAA → ABA: [10, 32]**

**IC → ABA: [29, 107]**

**IC → AVVP: [3, 29]**

## ELECCIÓN DEL MÉTODO DE REPRESENTACIÓN DE CONOCIMIENTO




## MÉTODO PROBABILISTA CLÁSICO

- **Orígenes: años 60**
- **Objetivo: desarrollo de sistemas de diagnóstico basados en el teorema de Bayes**
- **Ej.: medicina**
  - ▶ Posibles hallazgos (ej.: síntomas):  $e_1, \dots, e_m$
  - ▶ Posibles diagnósticos:  $d_1, \dots, d_n$
  - ▶ Se quiere conocer:  $P(d_1, \dots, d_n | e_1, \dots, e_m)$
  - ▶ Se conoce:  $P(e_1, \dots, e_m | d_1, \dots, d_n)$
  - ▶ Solución: teorema de Bayes

## MÉTODO PROBABILISTA CLÁSICO (cont.)

$$P(d_1, \dots, d_n | e_1, \dots, e_m) = \frac{P(e_1, \dots, e_m | d_1, \dots, d_n) \cdot P(d_1, \dots, d_n)}{\sum_{d'_1, \dots, d'_n} P(e_1, \dots, e_m | d'_1, \dots, d'_n) \cdot P(d'_1, \dots, d'_n)}$$



**H1: diagnósticos  
exclusivos y exhaustivos**

$$P(d_i | e_1, \dots, e_m) = \frac{P(e_1, \dots, e_m | d_i) \cdot P(d_i)}{\sum_j P(e_1, \dots, e_m | d_j) \cdot P(d_j)}$$


**H2: independencia  
condicional**

$$P(d_i | e_1, \dots, e_m) = \frac{P(e_1 | d_i) \cdot \dots \cdot P(e_m | d_i) \cdot P(d_i)}{\sum_j P(e_1 | d_j) \cdot \dots \cdot P(e_m | d_j) \cdot P(d_j)}$$

- **H1 y H2 no son válidas en casos reales  $\Rightarrow$  MYCIN  $\Rightarrow$  redes bayesianas (Judea Pearl, años 80)**

## REDES BAYESIANAS

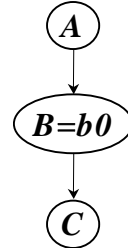
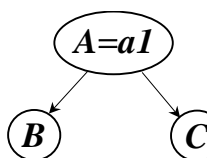
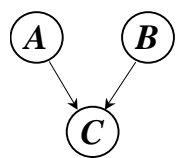
- **Red bayesiana: G.D.A. + separación direccional**
- **Nodo: variable aleatoria con valores exclusivos y exhaustivos**
- **Enlace  $\rightarrow$  T.P.C.:  $P(Y=y | X_1=x_1, \dots, X_n=x_n)$**



- **Probabilidad conjunta:  $P(n_1, \dots, n_m) = \prod_i P(n_i / pa(n_i))$**
- **Probabilidad a posteriori:  $P(n_i | e) / e = \cup \{N_j = n_j\}_{j \in \{1, \dots, m\} - \{i\}}$**
- **Modelos probabilísticos de interacción causal: General, Q, Y, MAX, MIN, SUM...**

## PROPIEDAD DE SEPARACIÓN DIRECCIONAL

- **S.D.:** Refleja la noción humana de causalidad

Independencia condicional entre hijos y padres de un nodo, dado su valor	Independencia condicional entre efectos, dado el valor de la causa	Independencia a priori de los nodos sin antepasados comunes
 <p><math>P(c / a, b0) = P(c   b0)</math></p>	 <p><math>P(b / a1, c) = P(b   a1)</math></p>	 <p><math>P(a / b) = P(a)</math></p>

- Si estas relaciones no fueran ciertas en un dominio particular, habría que añadir arcos

## PROPAGACIÓN DE LA EVIDENCIA

- A partir de la probabilidad conjunta: complejidad exponencial con el número de nodos

$$P(x | e) = \frac{P(x, e)}{P(e)} = \alpha \cdot \sum_{x_i \setminus \{x, e\}} P(x_1, \dots, x_n)$$


- En poliárboles,

$$P(x | e) = \frac{P(x, e)}{P(e)} = \alpha \cdot P(x, e_x^+, e_x^-) = \alpha \cdot P(x, e_x^+) \cdot P(e_x^- | x, e_x^+)$$

$$= \alpha \cdot P(x, e_x^+) \cdot P(e_x^- | x) = \alpha \cdot \pi(x) \cdot \lambda(x)$$

## PROPAGACIÓN DE LA EVIDENCIA (cont.)


- Existen fórmulas de carácter recursivo para el cálculo de  $\pi$  y  $\lambda$  en cada nodo.
- Dichas fórmulas se prestan a una implementación distribuida



- **Complejidad: proporcional al camino más largo de la red**

## PROPAGACIÓN DE LA EVIDENCIA (cont.)


- **Método de Agrupamiento:** se agrupan variables en nodos de mayor tamaño para que desaparezcan los bucles  $\rightarrow$  árbol de cliques
- **Método de Condicionamiento:** se asignan valores a ciertas variables para romper los bucles, se propaga la evidencia para cada posible distribución de dichos valores y se ponderan las probabilidades obtenidas para cada distribución



- **Método de Simulación:** se estiman las probabilidades a partir de una serie de ensayos
  - **Ventaja:** es independiente de la topología de la red
  - **Inconveniente:** Ensayos inútiles (*Logic Sampling*)  $\rightarrow$  Nuevos métodos

**PUERTA O PROBABILISTA (NOISY OR-GATE)**

- Variables binarias → {ausente, presente}
- $X_i$ : causa  $i$ ,  $Y$ : efecto




- $c_i \equiv P(Y=+y / X_1=-x_1, \dots, X_i=+x_i, \dots, X_n=-x_n)$
- T.P.C.:  $P(+y | \bar{x}) = 1 - \prod_{i \in T_x} (1 - c_i)$

$P(+y   x_1, x_2)$	$-x_1$	$+x_1$
$-x_2$	0	$c_1$
$+x_2$	$c_2$	$1 - (1 - c_1)(1 - c_2)$

**PUERTA MAX PROBABILISTA (NOISY MAX-GATE)**

- Variables graduadas → {ausente < grado1 < ... < gradog}
- ▶ Fiebre → {ausente(0) < leve(1) < moderada(2) < severa(3)}
- $X_i$ : causa  $i$ ,  $Y$ : efecto



- $c_y^{x_i} \equiv P(Y = y | X_1 = 0, \dots, X_i = x_i, \dots, X_n = 0)$


### PUERTA MAX PROBABILISTA (cont.)

• T.P.C.:  $P(y | \bar{x}) = \sum_{\bar{z} | \max \bar{z}=y} \prod_i c_{z_i}^{x_i}$

$P(y   X_1=x_1, X_2=x_2)$	$c_0^{x_1}$	$c_1^{x_1}$	...	$c_{g_Y-1}^{x_1}$	$c_{g_Y}^{x_1}$
$c_0^{x_2}$	Y=0	Y=1	...	Y=g <sub>Y</sub> -1	Y=g <sub>Y</sub>
$c_1^{x_2}$	Y=1	Y=1	...	Y=g <sub>Y</sub> -1	Y=g <sub>Y</sub>
⋮	⋮	⋮	⋮	⋮	⋮
$c_{g_Y-1}^{x_2}$	Y=g <sub>Y</sub> -1	Y=g <sub>Y</sub> -1	...	Y=g <sub>Y</sub> -1	Y=g <sub>Y</sub>
$c_{g_Y}^{x_2}$	Y=g <sub>Y</sub>	Y=g <sub>Y</sub>	...	Y=g <sub>Y</sub>	Y=g <sub>Y</sub>

### REDES BAYESIANAS DINÁMICAS

- **Tiempo discreto**
- **Nodos:** se crea una copia de cada variable para cada instante de tiempo
- **Enlaces:** se reproduce un modelo causal estático para cada instante y se establecen arcos entre variables de modelos consecutivos (procesos markovianos)




## REDES BAYESIANAS DINÁMICAS (cont.)

- **Inconvenientes para nuestro dominio:**
  - Se obtienen redes muy complejas estructuralmente
  - Cada variable debería representar un evento irreversible (sólo ocurre una vez a lo largo del tiempo) y no un evento que puede producirse múltiples veces
  - Nuestro dominio no es markoviano ya que puede haber diferentes retardos entre dos nodos evento

## REDES BAYESIANAS CON NODOS TEMPORALES

- **Tiempo dividido en cada nodo en intervalos de diferente duración**
- **Nodos:** representan un evento o cambio de estado de una variable (como máximo un cambio a lo largo del tiempo)
  - Valor de un nodo: intervalo en que ocurre el evento
  - Cada intervalo está definido relativamente a la ocurrencia de un evento padre

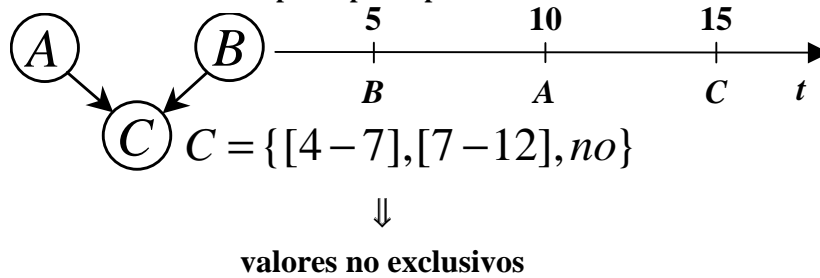


- **Enlaces:** representan relaciones causales temporales entre nodos

**REDES BAYESIANAS CON NODOS TEMPORALES (cont.)**


• **Inconvenientes:**

- No utiliza modelos canónicos probabilistas adaptados a procesos temporales → siempre el modelo general
- La ocurrencia en un instante determinado de un nodo evento con padres no constituye evidencia directa → escenarios
- La definición de los valores de un nodo mediante tiempos relativos a cada uno de sus nodos padre puede producir inconsistencias:



**PUERTA O PROBABILISTA TEMPORAL (TEMPORAL NOISY OR-GATE)**

- **Variable V:** evento temporal →  $\{v[0], v[1], \dots, v[t_v], v[nunca]\}$
- $V=v[i]$  significa “El evento V tiene lugar en el instante i.”
- $X_i$ : causa i, Y: efecto



- $c_{y[k]}^{x_i[j_i]} \equiv P(y[k] \mid x_1[nunca], \dots, x_i[j_i], \dots, x_n[nunca])$   
 $j_i \in \{0, \dots, t_{x_i}\}, k \in \{0, \dots, t_y\}$

**PUERTA O PROBABILISTA TEMPORAL (cont.)**


- **TPC: Puerta O Probabilista Temporal → Puerta MAX probabilista**  
(nunca < t<sub>Y</sub> < t<sub>Y</sub>-1 < ... < 1 < 0)

$P(y[k]   x_1[j_1], x_2[j_2])$	$C_{y[nunca]}^{x_1[j_1]}$	$C_{y[t_Y]}^{x_1[j_1]}$	...	$C_{y[1]}^{x_1[j_1]}$	$C_{y[0]}^{x_1[j_1]}$
$C_{y[nunca]}^{x_2[j_2]}$	y[nunca]	y[t <sub>Y</sub> ]	...	y[1]	y[0]
$C_{y[t_Y]}^{x_2[j_2]}$	y[t <sub>Y</sub> ]	y[t <sub>Y</sub> ]	...	y[1]	y[0]
⋮	⋮	⋮	⋮	⋮	⋮
$C_{y[1]}^{x_2[j_2]}$	y[1]	y[1]	...	y[1]	y[0]
$C_{y[0]}^{x_2[j_2]}$	y[0]	y[0]	...	y[0]	y[0]

**RED PARA MODELADO DE FALLOS EN UN GENERADOR DE VAPOR**

- **Horizonte o rango temporal:** 12 minutos
- **Unidad temporal:** 20 segundos
  - *FAT = fat[3]* significa “incremento en el flujo de agua de atemperación producido entre los segundos 41 y 60”
- **Parámetros independientes por arco:**

$$C_{y[k]}^{x_i[j_i]} \quad j_i \in \{1, \dots, 36, nunca\}, k \in \{1, \dots, 36\}$$



## ADQUISICIÓN DE LOS PARÁMETROS DE LA RED

- Obtener  $c_{y[k]}^{x_i[j_i]}$  requeriría averiguar:
  - Dado que  $X_i$  tiene lugar en un cierto intervalo de 20 sgs., ¿cuál es la probabilidad de que su efecto  $Y$  ocurra en ese mismo intervalo, si el resto de sus causas están ausentes?, ¿y la probabilidad de que  $Y$  ocurra en el siguiente intervalo? y así sucesivamente.
- Disponíamos de los parámetros  $\tilde{c}_Y^{X_i}(\Delta t)$ :
  - 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 sgs., si el resto de sus causas están ausentes?, ¿y la probabilidad de que  $Y$  ocurra en el intervalo siguiente al siguiente? y así sucesivamente.

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

## IMPLEMENTACIÓN


- Entorno de desarrollo utilizado: Elvira (creado conjuntamente por varias universidades españolas)

<http://www.ia.uned.es/~fjdiez/bayes/elvira/>

- Tiempo empleado en inferencia: por debajo del minuto a partir de métodos exactos

## EJEMPLO

RANGO TEMPORAL: {1, ...,10}



$$c[6] \Rightarrow a[4], a[5], b[2], b[3]$$

$$c[6], d[7] \Rightarrow a[5]$$

EJEMPLO

27

## EJEMPLO (cont.)

**Node Properties (Top Window)**

Nodo	Valores	Relación
a1	1.0E-5	
a2	1.0E-5	
a3	1.0E-5	
a4	1.0E-5	
a5	1.0E-5	
a6	1.0E-5	
a7	1.0E-5	
a8	1.0E-5	
a9	1.0E-5	
a10	1.0E-5	
nunca	0.9999	

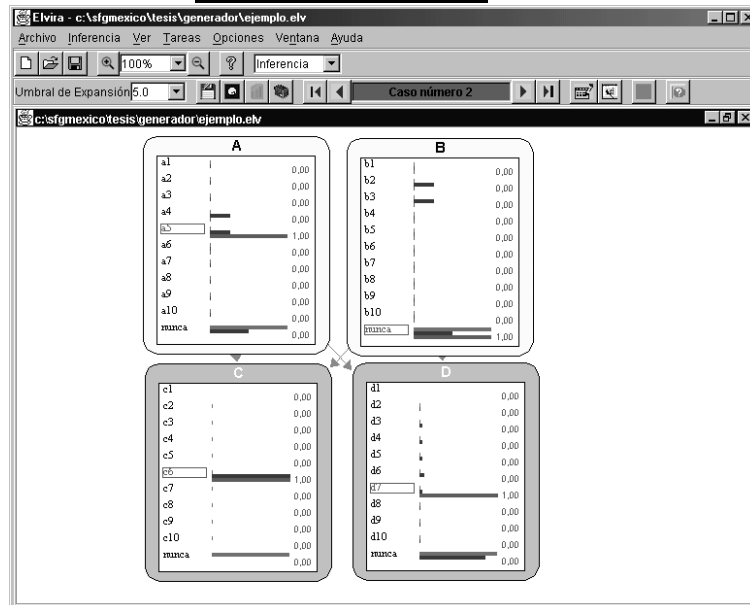
**Node Properties (Bottom Window)**

Nodo	Valores	Relación					
Tipo de relación	General	Probabilista					
Selección	Todos los parámetros	Valores					
Selección	Parámetros independientes	Probabilidades					
Selección	Parámetros canónicos	Henrion					
Tipo de relación	MAX	Probabilista					
Selección	Valores	CPT					
Selección	Parámetros canónicos	Henrion					
	A	A	A	A	A	A	A
C	a1	a2	a3	a4	a5	a6	a7
c1	0	0	0	0	0	0	0
c2	0.1	0	0	0	0	0	0
c3	0.1	0.1	0	0	0	0	0
c4	0	0.1	0.1	0	0	0	0
c5	0	0	0.1	0.1	0	0	0
c6	0	0	0	0.1	0.1	0	0
c7	0	0	0	0	0.1	0.1	0
c8	0	0	0	0	0	0.1	0.1
c9	0	0	0	0	0	0	0.1
c10	0	0	0	0	0	0	0

EJEMPLO

28

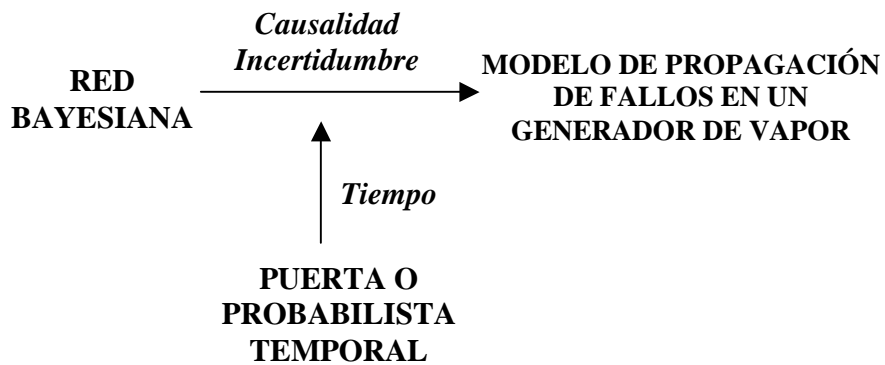
### EJEMPLO (cont.)



EJEMPLO

29

### CONCLUSIONES



CONCLUSIONES

30