

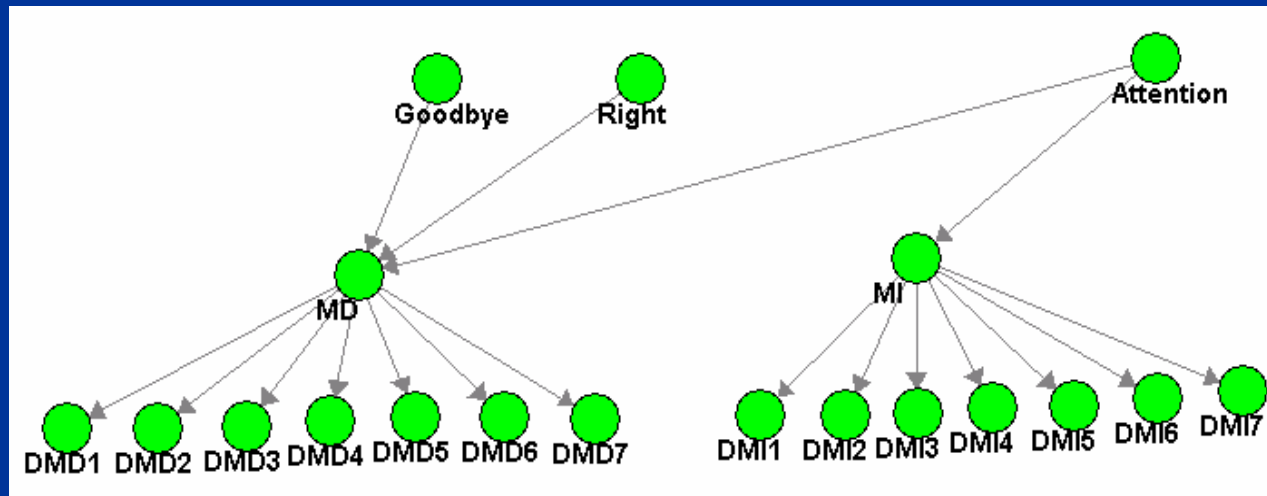
Modelos Gráficos Probabilistas

L. Enrique Sucar

INAOE

Sesión 12:

Redes Bayesianas: extensiones y aplicaciones




RB – Extensiones y Aplicaciones

- **Extensiones**
 - Redes dinámicas
 - Redes temporales
 - Variables continuas
- **Ejemplos de aplicaciones**
 - Diagnóstico en plantas eléctricas
 - Endoscopía
 - Reconocimiento de actividades
 - Reconocimiento de gestos
 - Predicción de ozono

Redes Bayesianas Dinámicas (RBD)

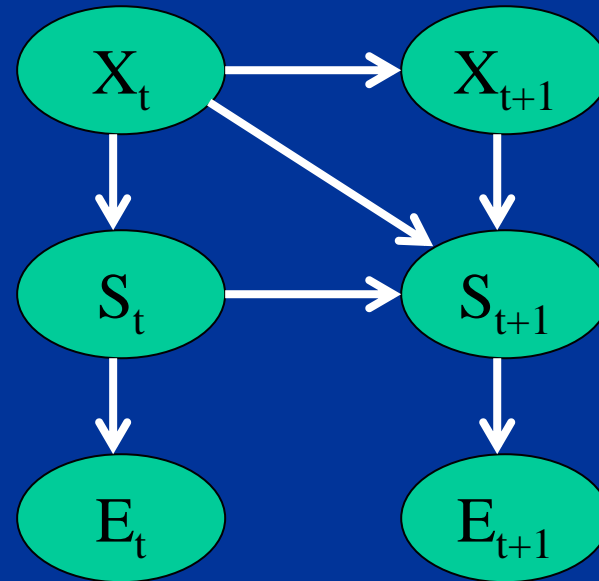
- Representan procesos dinámicos
- Consisten en una representación de los estados del proceso en un tiempo (red base) y las relaciones temporales entre dichos procesos (red de transición)
- Se pueden ver como una generalización de las cadenas (ocultas) de Markov

Red base



T

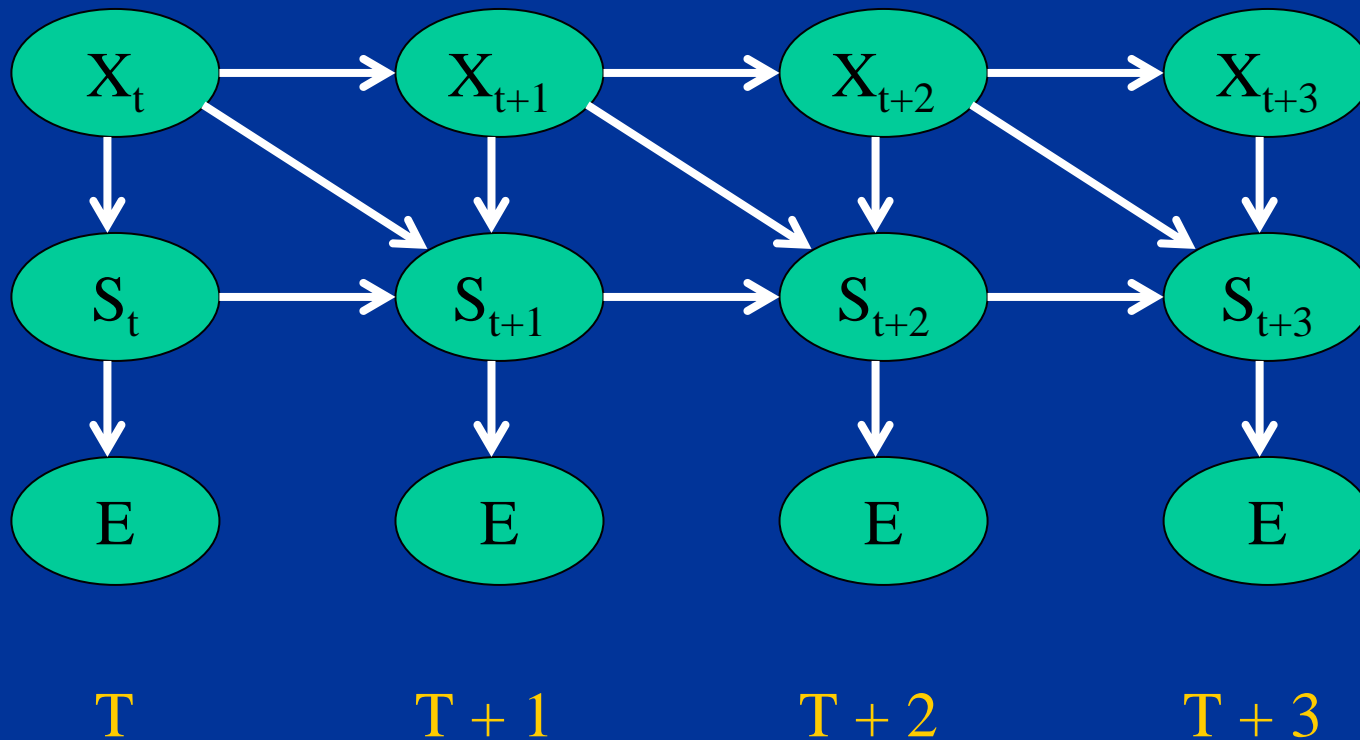
Red de Transición



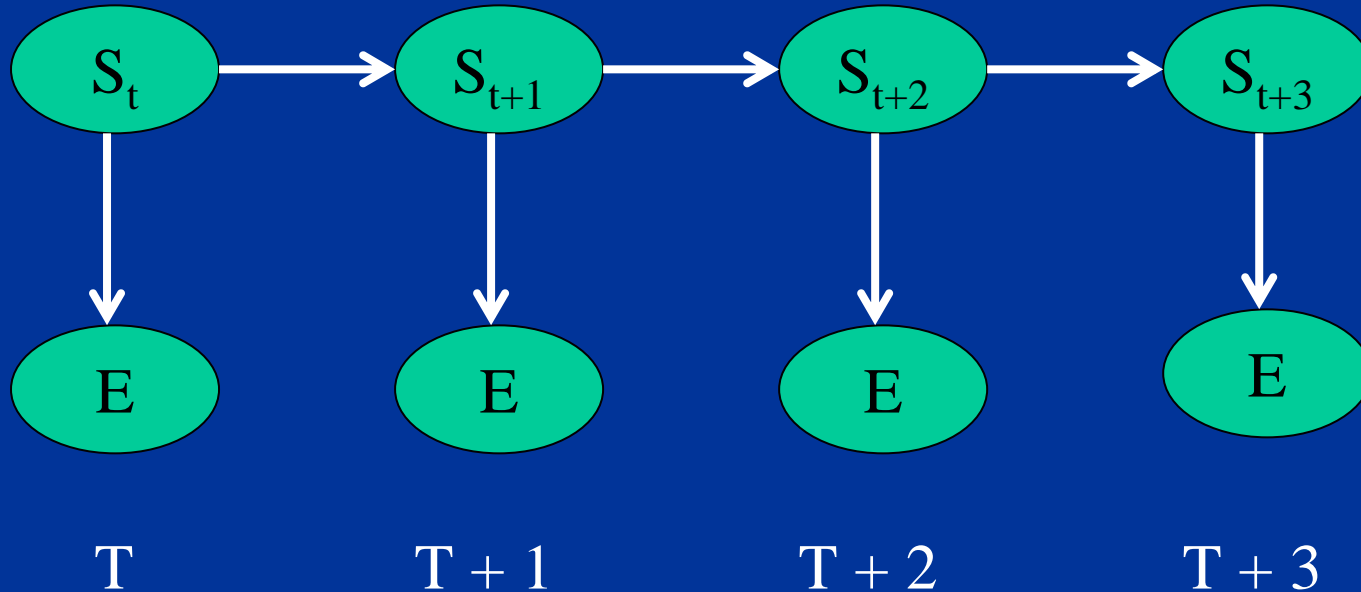
T

T + 1

Modelo expandido (4 etapas temporales)



Ejemplo de RBD (equiv. HMM)



Parámetros:

- Probabilidades iniciales: $P(S_t)$
- Probabilidades de transición: $P(S_{t+1}|S_t)$
- Probabilidades de observación: $P(E|S_t)$

Suposiciones Básicas


- Proceso markoviano - el estado actual sólo depende del estado anterior (sólo hay arcos entre tiempos consecutivos)
- Proceso estacionario en el tiempo - las probabilidades de transición, $P(S_{t+1} | S_t)$, no cambian en el tiempo

Algoritmos

- Propagación
 - Aplican los mismos algoritmos de propagación de redes estáticas
 - Se incremento el problema de complejidad computacional, utilizándose técnicas de simulación como los filtros de partículas
- Aprendizaje
 - Existen extensiones de las técnicas de aprendizaje paramétrico y estructural para RBD

RBD – Aprendizaje

- El aprendizaje se divide en 2 partes:
 - Aprender la estructura “estática”
 - Aprender la estructura de “transición”



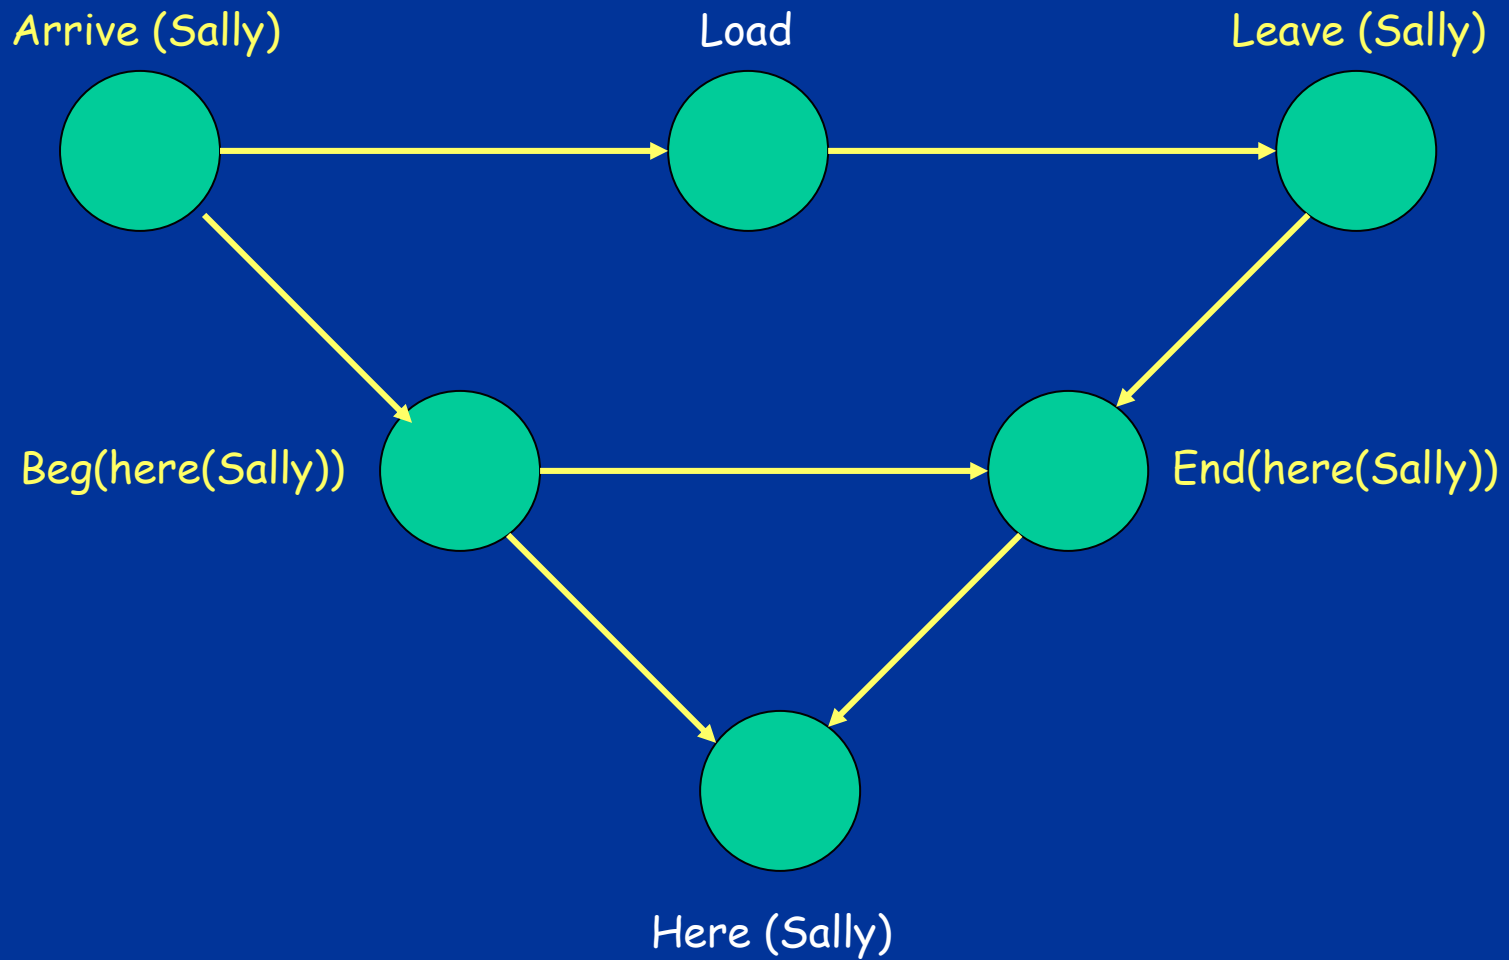
Redes Temporales

- Representaciones alternativas a RBD que incorporan aspectos temporales
- Se orientan a representar intervalos de tiempo o eventos en el tiempo vs estados
- Existen diferentes propuestas, dos ejemplos representativos son:
 - Redes de tiempo (*time net*) [Kanazawa]
 - Redes de nodos temporales (TNBN) [Arroyo]

Red de tiempo

- La representación se basa en 2 tipos de eventos (nodos):
 - Eventos: un hecho que ocurre de manera instantánea
 - Hechos: una situación que es verdadera durante cierto intervalo de tiempo
- Cada hecho tiene asociado un evento de inicio y un evento de terminación

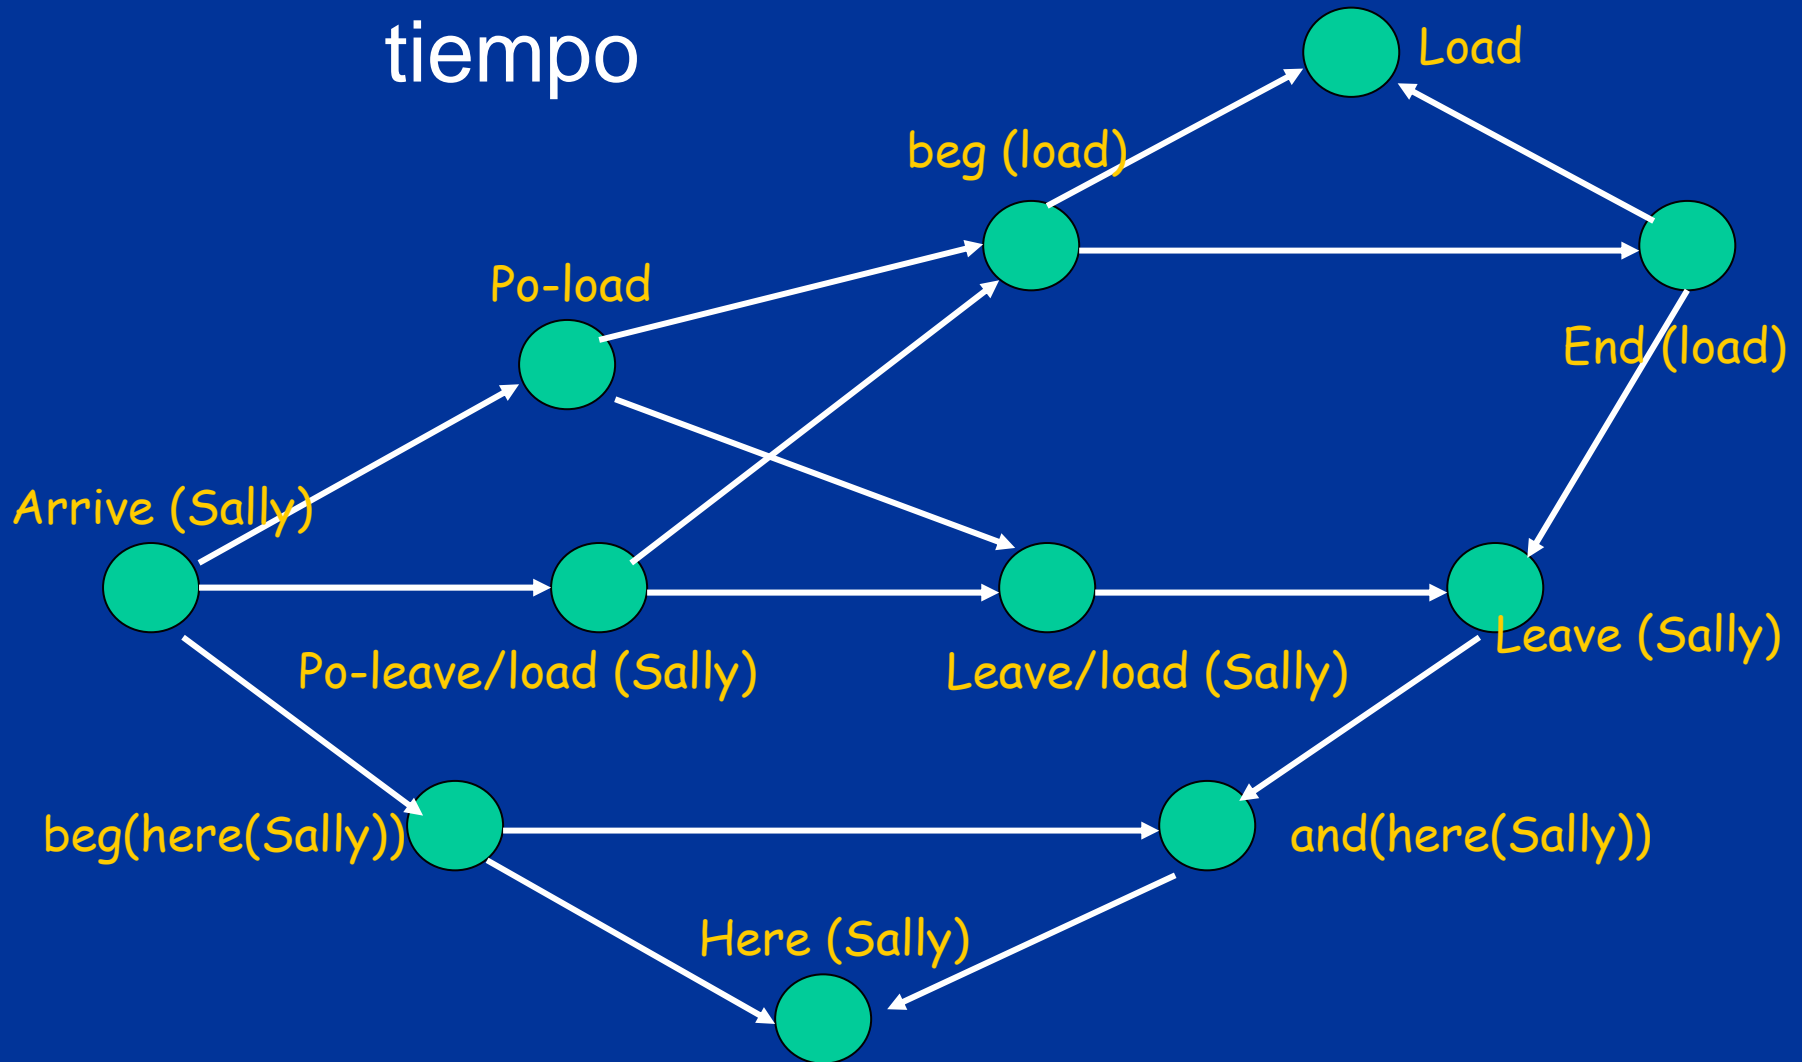
Ejemplo de redes de tiempo



Redes de tiempo

- Para poder representar alternativas se utilizan nodos virtuales (*potencial events*)
- Cada nodo tiene asociados como valores "tiempos" de ocurrencia, por ejemplo: Arrive(sally): [2 - 6]
- Se asocian a cada nodo una tabla de probabilidades dados sus padres
- La propagación se realiza mediante técnicas de simulación estocástica

Ejemplo de redes de tiempo



Redes de Nodos Temporales

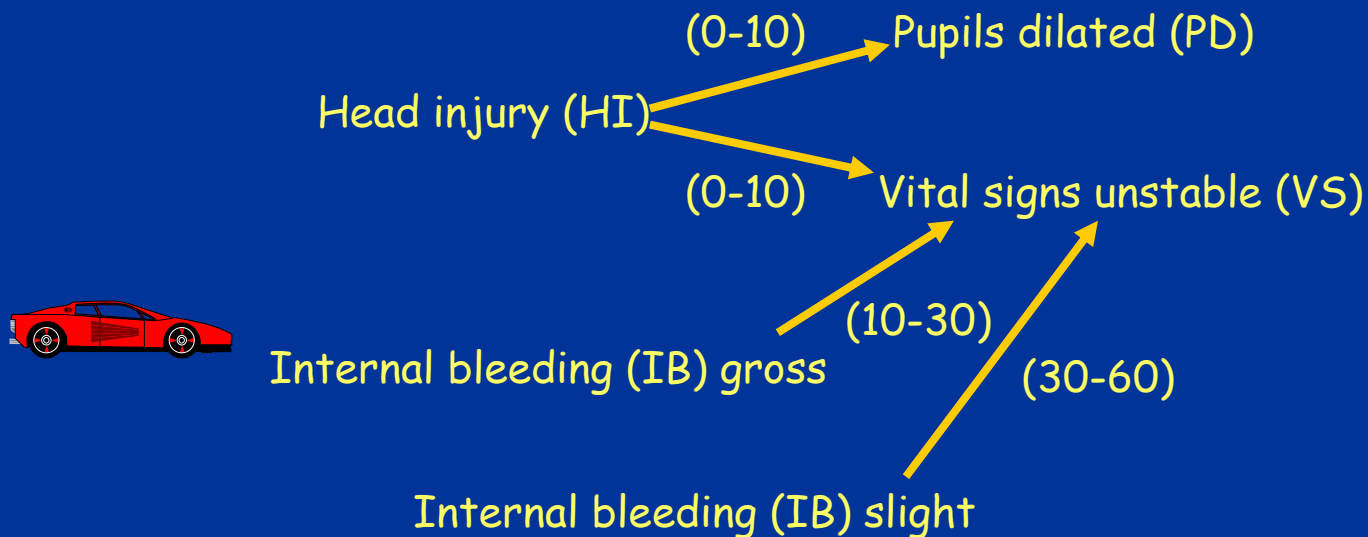
- Representan cambios de estado (eventos) de las variables
- Tienen dos tipos de nodos:
 - Nodos de estado - representan variables de estado como en las RB
 - Nodos temporales - representan cambios de estado de una variable

Nodo Temporal

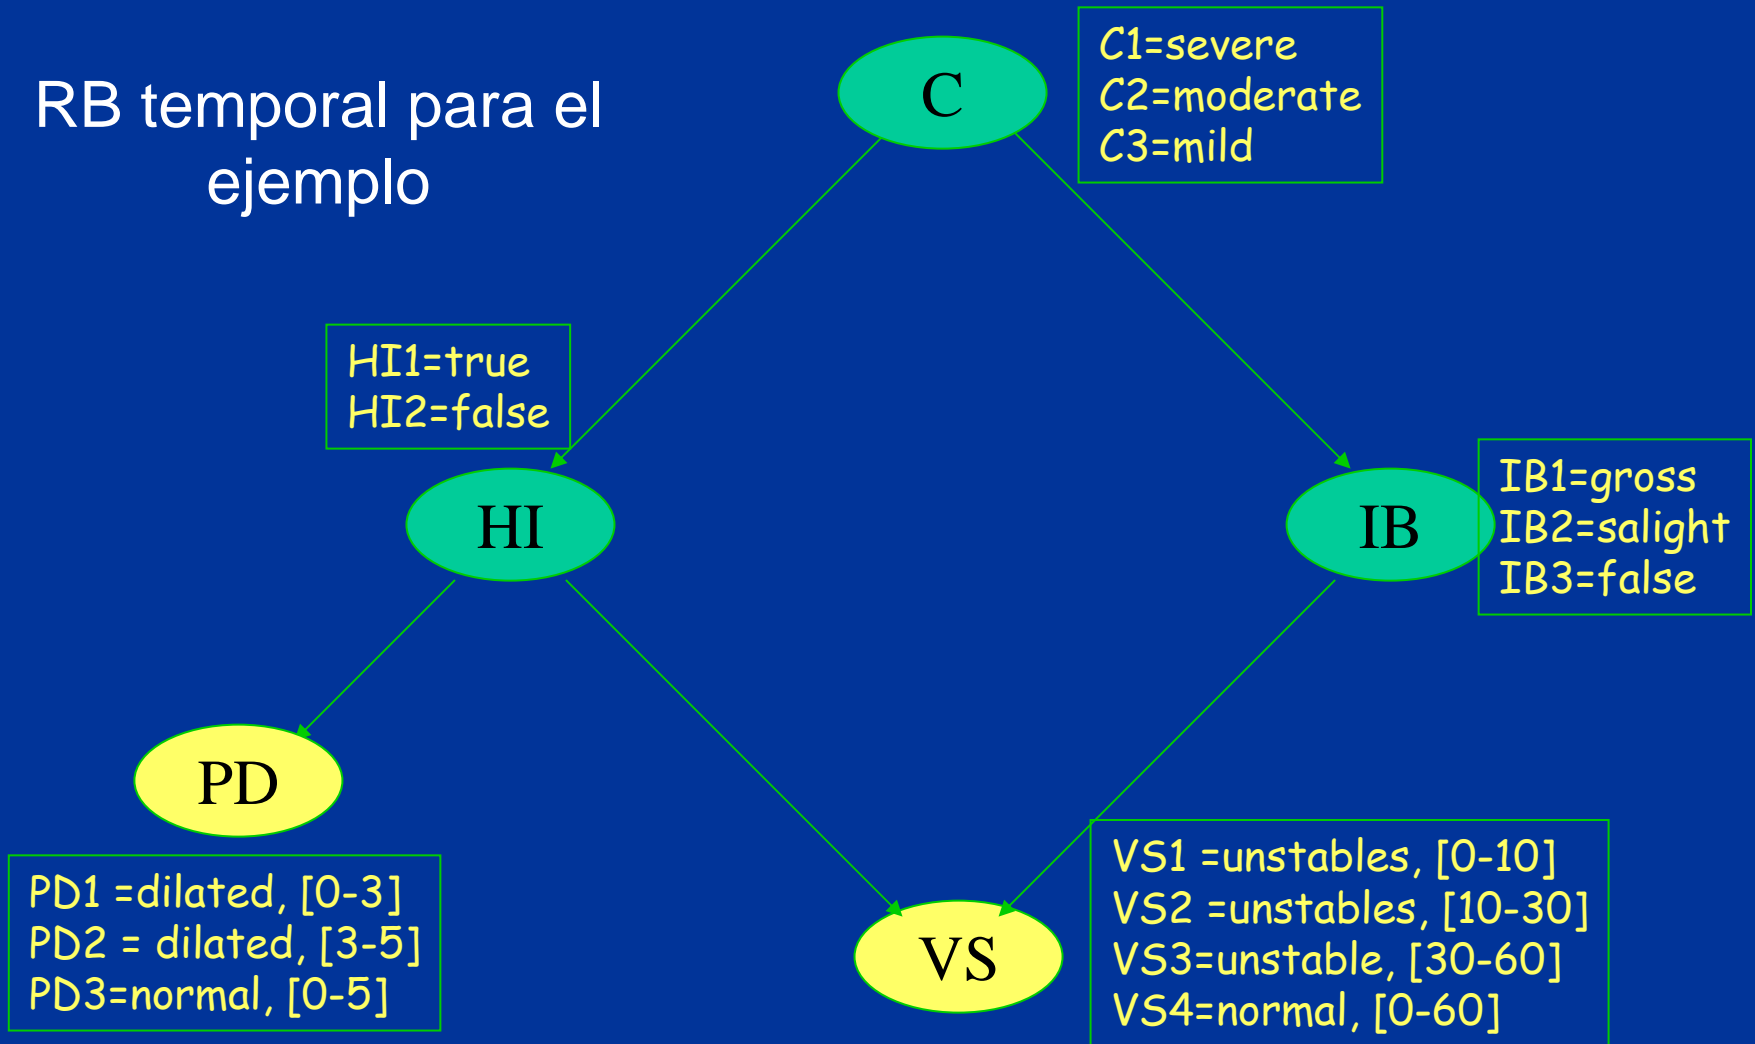
- Nodo que representa un "evento" o cambio de estado de una variable de estado
- Sus valores corresponden a diferentes intervalos de tiempo en que ocurre el cambio
- Ejemplo: *incremento de nivel*
 - Valores (3):
 - * Cambio 0 - 1 0
 - * Cambio 10 - 50
 - * No Cambio

Redes con Nodos Temporales

- Permiten una representación más compacta de ciertos dominios que las redes dinámicas
- Ejemplo (accidente automovilístico):



RB temporal para el ejemplo



TNBN

- Para cada nodo temporal se definen un conjunto de valores que corresponden a intervalos de tiempo y las probabilidades asociadas
- La propagación se hace de la misma manera que en redes estáticas

Variables Continuas

- Las redes bayesianas normalmente manejan variables multi-valuadas discretas.
- Cuando se presentan variables continuas (temperatura, estatura, etc.), éstas se discretizan en un número de intervalos y se manejan como si fueran discretas.
- Este enfoque presenta desventajas:
 - Si el número de intervalos es pequeño, se pierde precisión.
 - Si el número de intervalos es grande, el modelo se vuelve demasiado complejo y se requiere gran cantidad de datos para estimar las probabilidades

Variables Continuas

- Otra alternativa es manejar directamente distribuciones continuas.
- Se han realizado pocos desarrollos en este sentido y la mayoría están limitados al manejo de distribuciones gaussianas:

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

Donde μ es el promedio y σ^2 es la varianza (σ es la desviación estándar). Esta se representa como $N(\mu, \sigma)$

Propagación con variables gaussianas

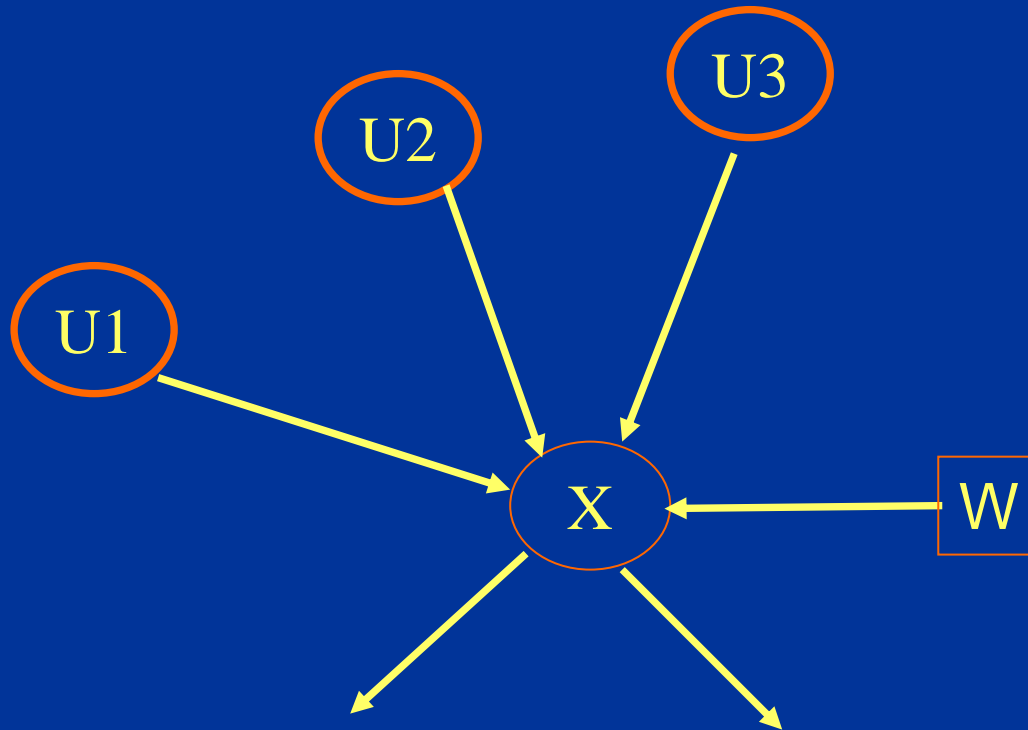
Suposiciones:

1. La estructura de la red es un poliárbol.
2. Todas las fuentes de incertidumbre no están correlacionadas y siguen el modelo gaussiano.
3. Existe una relación lineal entre variables (entre un nodo y sus padres):

$$X = b_1 U_1 + b_2 U_2 + \dots + b_n U_n + W_x$$

Donde X es una variable, las U_i son los padres de X , las b son coeficientes constantes y w representa el "ruido" (gaussiano con media 0)

RB con variables continuas



Propagación con variables gaussianas

- El método de propagación es análogo al de poliárboles con variables discretas.
- Se establece que en este caso las distribuciones marginales de todas las variables son también gaussianas:

$$P(X | E) = \alpha \pi(x) \lambda(x) = N(\mu_x, \sigma_x)$$

- El producto de gaussianas es una gaussiana (esto no aplica a otras distribuciones)

Propagación con variables gaussianas

- Los parámetros, μ y σ , se obtienen de los parámetros que envían los nodos padre e hijos con las siguientes expresiones:

$$\mu_x = \frac{\sigma_\pi \mu_\lambda + \sigma_\lambda \mu_\pi}{\sigma_\pi + \sigma_\lambda}$$
$$\sigma_x = \frac{\sigma_\pi \sigma_\lambda}{\sigma_\pi + \sigma_\lambda}$$

$$\mu_\pi = \sum_i b_i \mu_i^+$$

$$\sigma_\pi = \sum_i b_i^2 \sigma_{xi}^+$$

$$\mu_\lambda = \sigma_\lambda \sum_j \frac{\mu_j^-}{\sigma_j^-}$$

$$\sigma_\lambda = \left[\sum_j \frac{1}{\sigma_j^-} \right]^{-1}$$

Los mensajes que envían los nodos a sus padres e hijos se calculan de la siguiente manera:

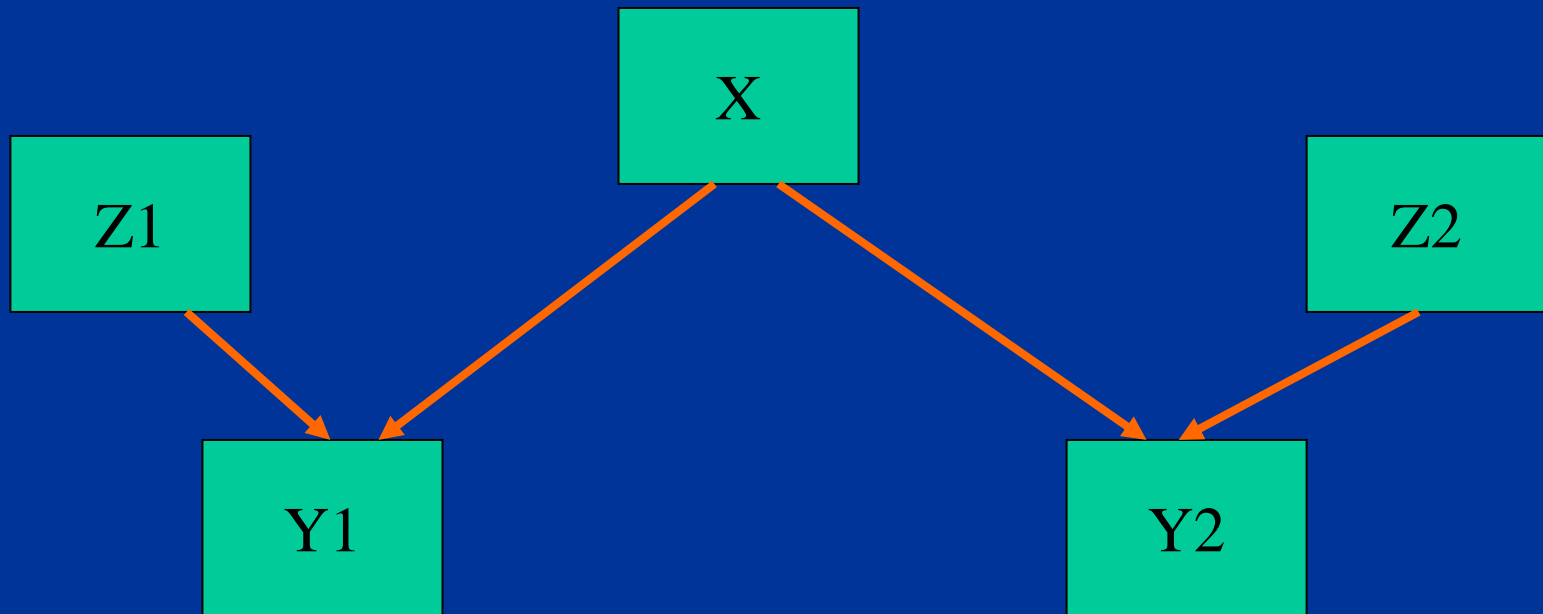
Mensaje que envía el nodo X a su padre i :

$$\begin{aligned}\mu_i^- &= (1/b_i) \left[\mu_\lambda - \sum_{k \neq i} b_k \mu_k^+ \right] \\ \sigma_i^- &= (1/b_i^2) \left[\sigma_\lambda + \sum_{k \neq i} b_k^2 \sigma_k^+ \right]\end{aligned}$$

Mensaje que envía el nodo X a su hijo j :

$$\begin{aligned}\mu_j^+ &= \frac{\sum_{k \neq j} \frac{\mu_k^-}{\sigma_k} + \frac{\mu_\pi}{\sigma_\pi}}{\sum_{k \neq j} \frac{1}{\sigma_k^-} + \frac{\mu_\pi}{\sigma_\pi}} \\ \sigma_j^+ &= \left[\sum_{k \neq j} \frac{1}{\sigma_k^-} + \frac{1}{\sigma_\pi} \right]^{-1}\end{aligned}$$

Ejemplo - RB con Variables Continuas



Ejemplo - propagación

- Dado:

- $y_1=8000, y_2=10,000, z_1=z_2=1000$

- $ds(y_1)=300, ds(y_2)=1000$

- Aplicando las ecuaciones para “diagnóstico”:

$$\mu_x = [(8-1)(1)^2 + (10-1)(0.3)^2] / [(1)^2 + (0.3)^2] = 7165$$

$$\sigma_x = [(0.3)^2(1)^2] / [(1)^2 + (0.3)^2] = 82369, ds(x) = 287$$

Extensiones

- El algoritmo básico para poli-árboles ha sido extendido a:
 - Redes multi-conectadas
 - Modelos híbridos (discretas y continuas)
- Por ejemplo, Hugin maneja modelos híbridos con variables gaussianas, pero con la restricción de que una variable continua no puede ser padre de una discreta
- Hay muy poco trabajo con otras distribuciones

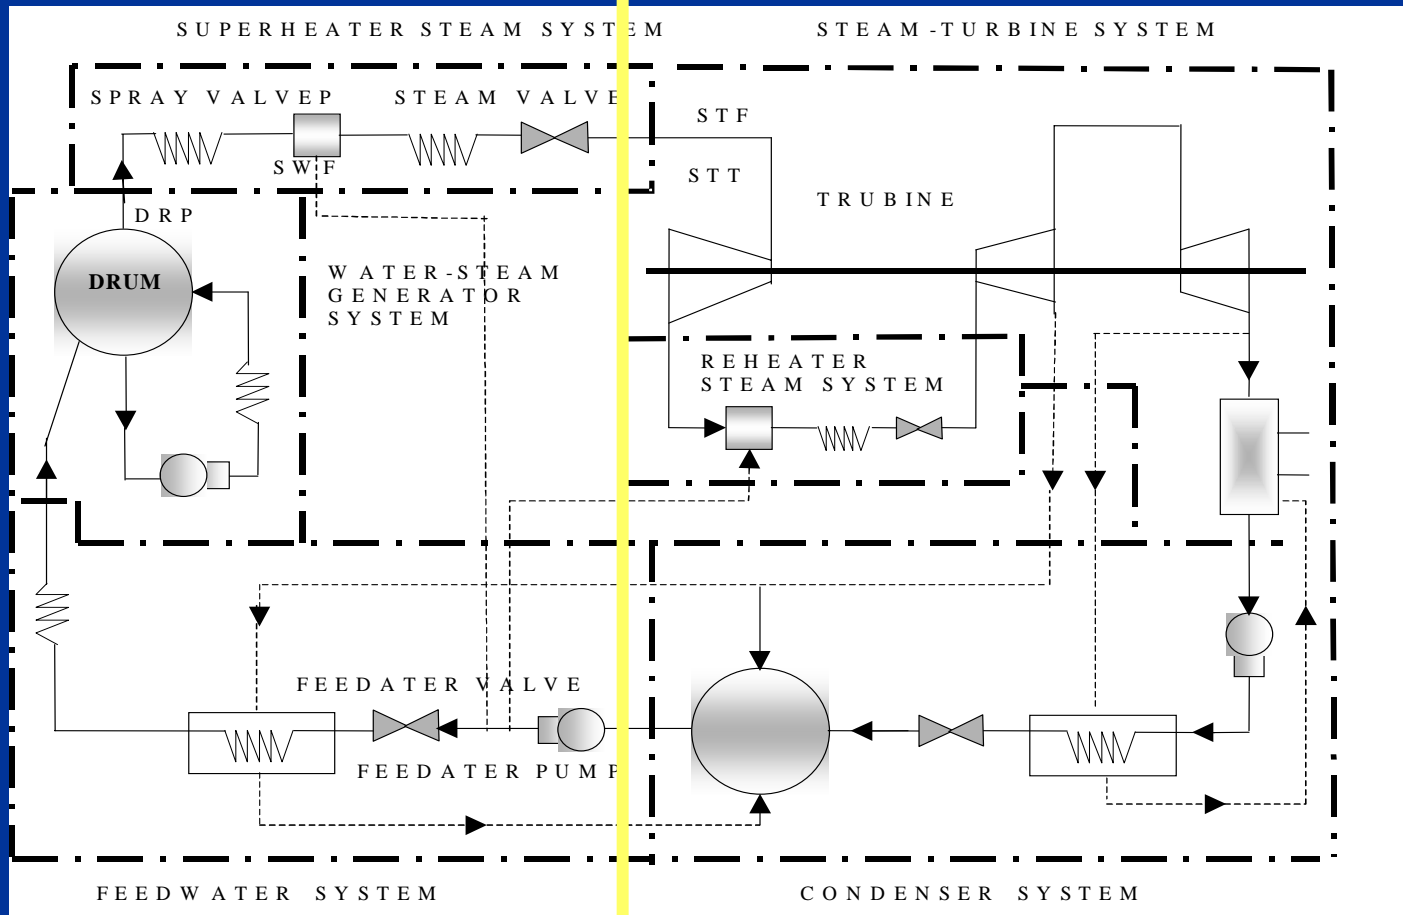
Aplicaciones

- Diagnóstico de plantas eléctricas
 - Red temporal
- Endoscopía
 - RB (mejora estructural)
- Reconocimiento actividades
 - RB (simulación estocástica)
- Reconocimiento de gestos
 - RBD (clasificador bayesiano dinámico)
- Predicción de ozono
 - RB (aprendizaje estructural)

Red Temporal para Diagnóstico de Plantas Eléctricas



Subsistema de una Planta Eléctrica



Diagnóstico y Predicción

- Se desea encontrar las posibles causas de una falla (diagnóstico) o predecir los efectos de una situación anormal o falla (predicción)
- El tiempo que transcurre entre los diferentes eventos en el proceso es crucial para la predicción y diagnóstico
- Parte del proceso de modela como una red temporal de eventos (nodos temporales)


Resultados Experimentales

Prueba	μ	σ
Predicción % RBS % Exactitud	87.37 84.48	9.19 14.98
Diagnóstico % RBS % Exactitud	84.25 80.00.	8.09 11.85
Diagnóstico y Predicción % RBS % Exactitud	95.85 94.92	4 .71 8.59


Endoscopía

- Herramienta para la observación directa del tubo digestivo
- El objetivo es ayudar al endoscopista a guiar el endoscopio en el colón (navegación semiautomática)
- Para ello se requieren reconocer los principales “objetos”, como son:
 - *Lumen* – el “centro” del tubo
 - *Divertículos* – “bolsas” en las paredes que se pueden confundir con el colón

Ejemplo de imagen



Segmentación – “región oscura”





Información de 3D – *histograma* *pq*



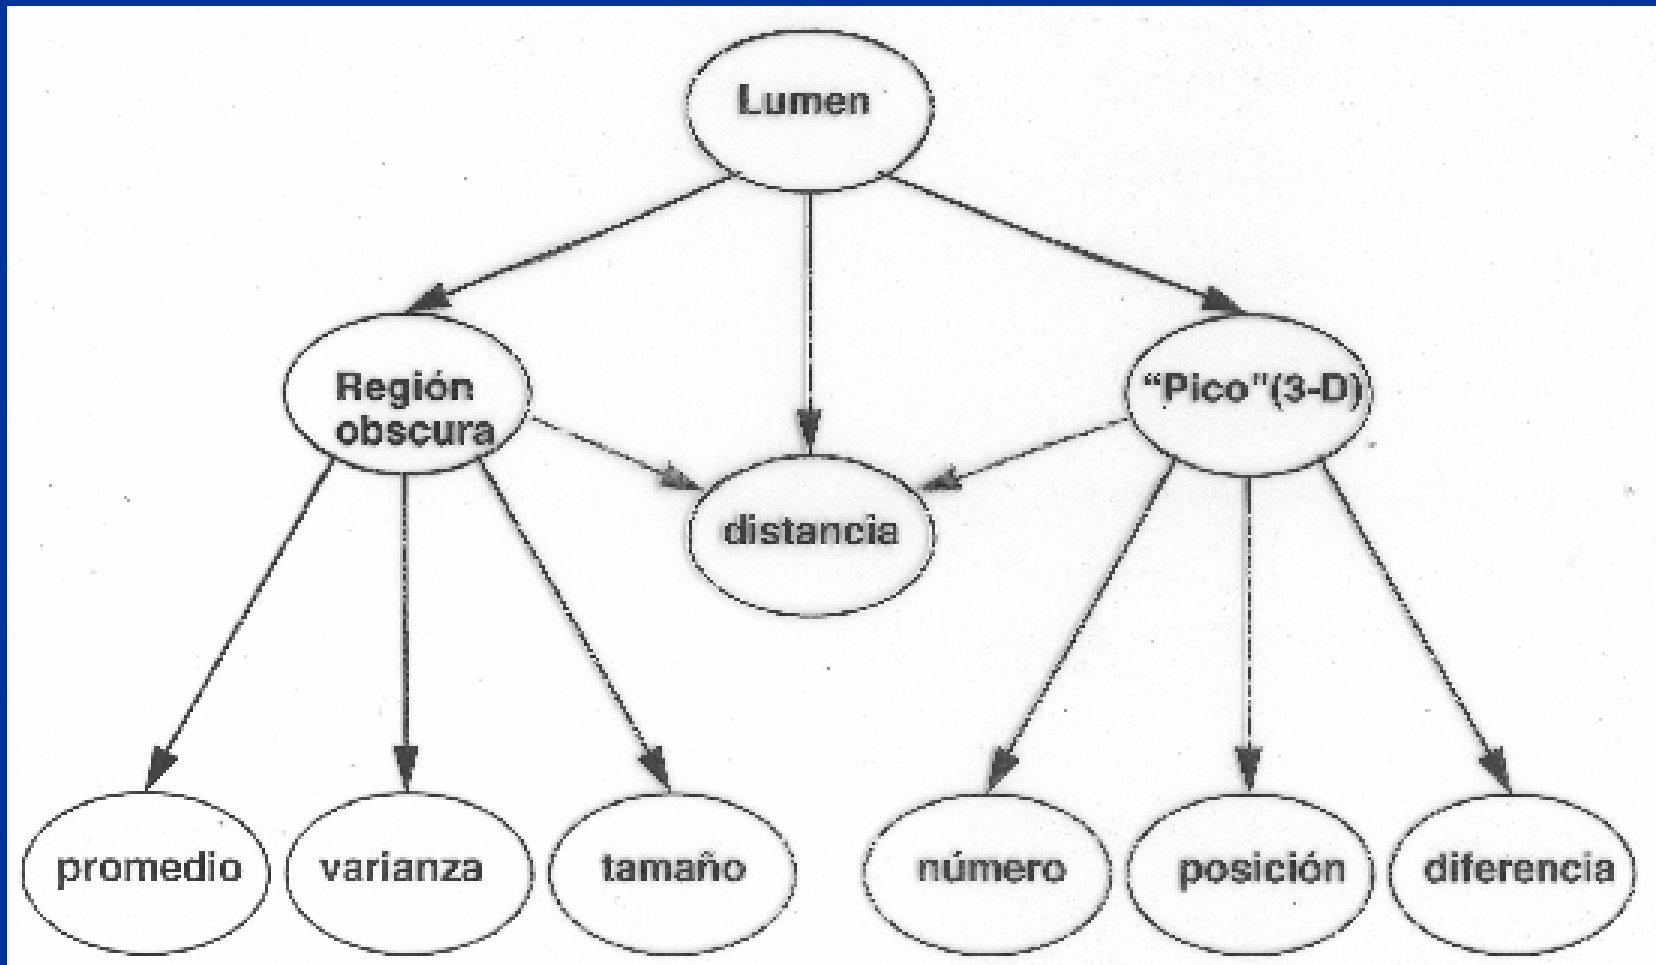
(a) Colon Image



(b) Depth map (needle diagram)




RB para endoscopía (parcial)



Metodología

- La estructura de la RB se construyó con la ayuda de un experto
- Los parámetros se obtuvieron de datos (videos de endoscopías)
- Posteriormente se mejoró la estructura utilizando pruebas de independencia

Endoscopio semi-automático



Sistema de ayuda



Sistema de ayuda

The screenshot displays a terminal-style interface for an endoscopy system. It is divided into several panels:


- status**: auto OFF search OFF
- interpretation**: No Lunen - lost view
- advice**: Pull-back and then push endoscope again
- pq-hist**: A small, mostly blank panel with a few faint characters.
- commands**: Auto ON/OFF, sEarch ON/OFF, Centre tip, Tape/scope, Learning, Quit
- video image [videotape]**: A large grayscale video feed of an endoscopic view. It features a white rectangular box in the center, a smaller white box in the bottom right, and a '+' icon in a small box on the right side.

Reconocimiento de actividades humanas

- Reconocer diversas actividades (caminar, correr, brincar, ...) en base a información visual
- Considerar los movimientos de brazos y piernas
- Varias actividades se pueden realizar al mismo tiempo
- Actividades continuas

Actividades

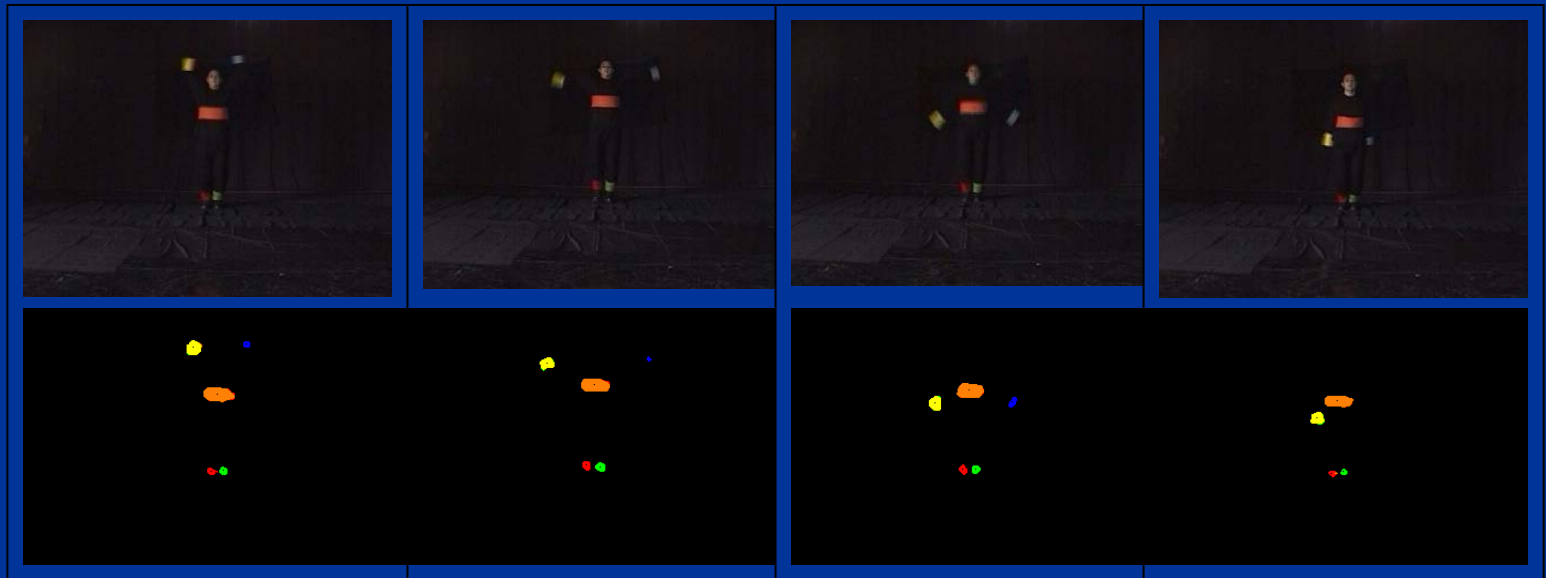
- Adiós
- Derecha
- Atención
- Caminar
- Brincar
- Aerobics



Adiós – derecha – atención



Actividades simultáneas: *brincar y atención*




Extracción de características

- Segmentación (marcas de colores)
- Seguimiento
- Parámetros de movimiento

Segmentación



Seguimiento



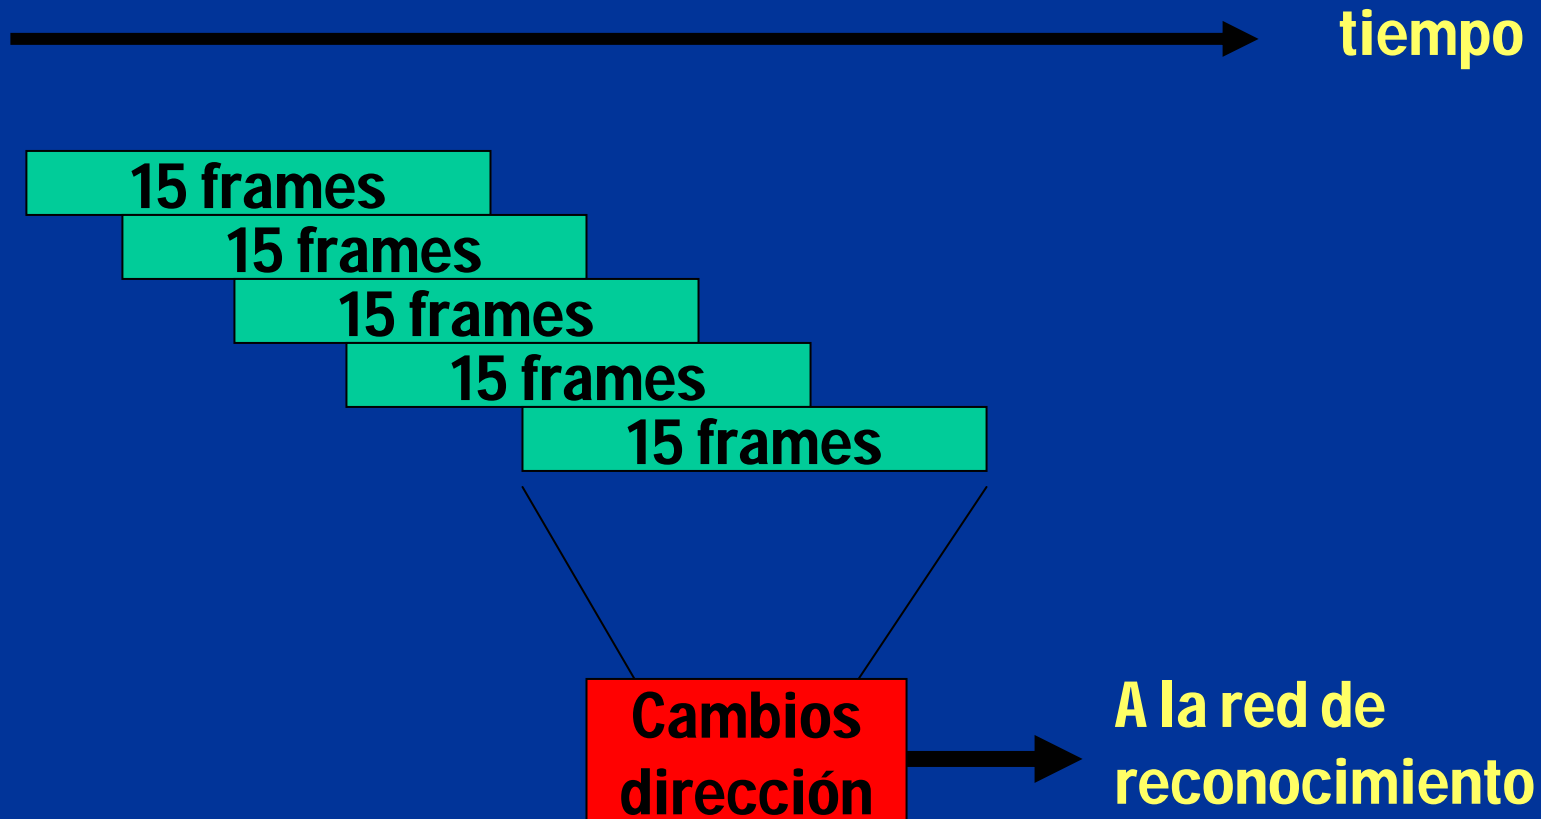
Parámetros

- Información de movimiento para cada extremidad (marcas):
 - Centroide (x,y)
 - Dirección de cambio entre cuadros (8 rangos)
 - Usar de 5 a 7 cambios en la secuencia (encontrado experimentalmente)

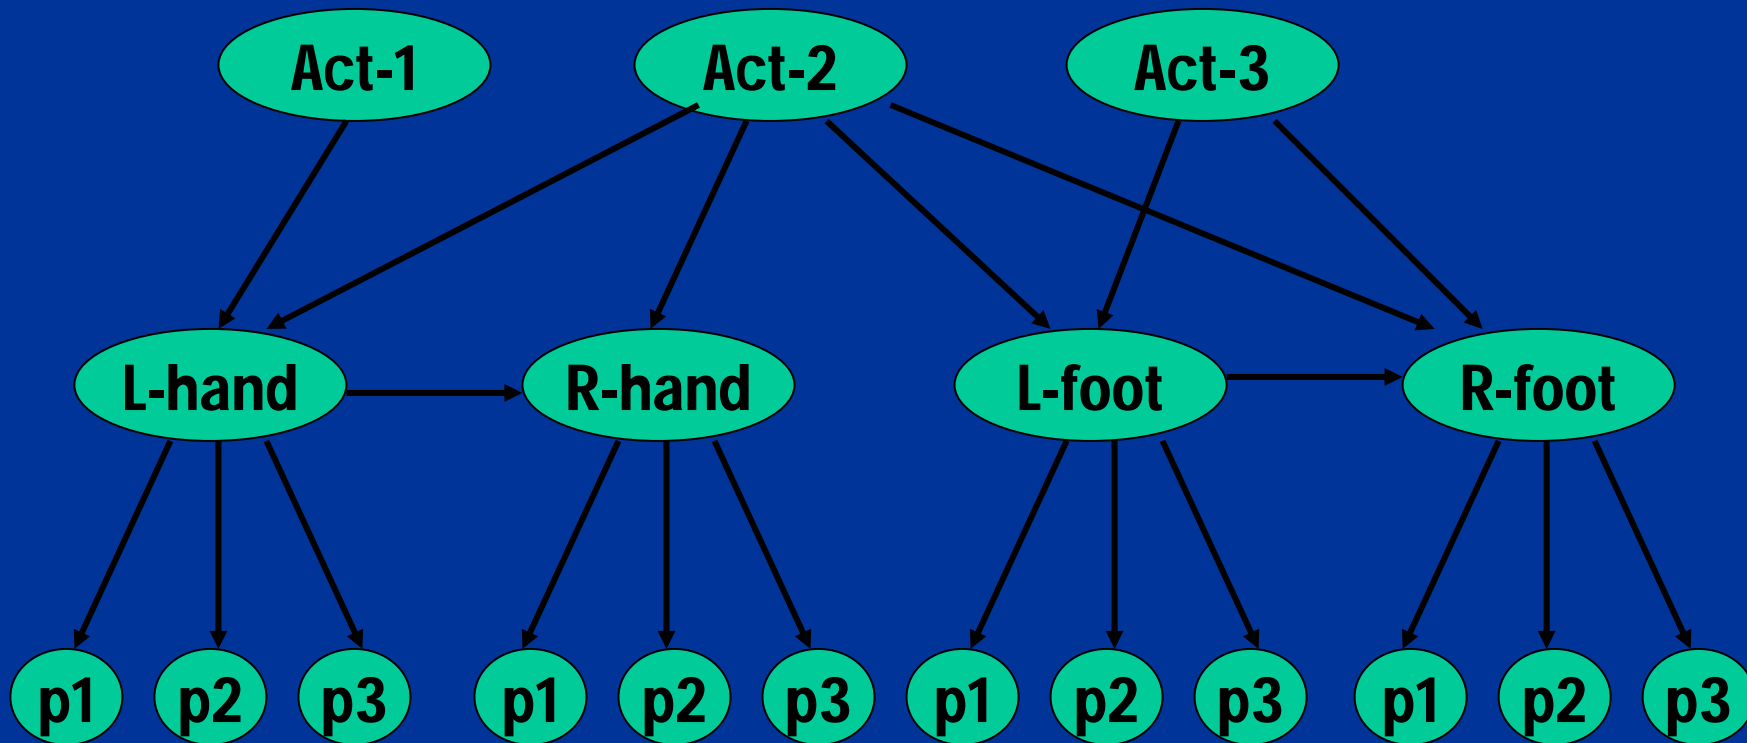
Modelo para reconocimiento

- Basado en una red bayesiana:
 - Un nodo para cada actividad
 - Un nodo por extremidad
 - 5 nodos que representan las direcciones de movimiento en el tiempo
- Puede reconocer actividades simultáneas y continuas

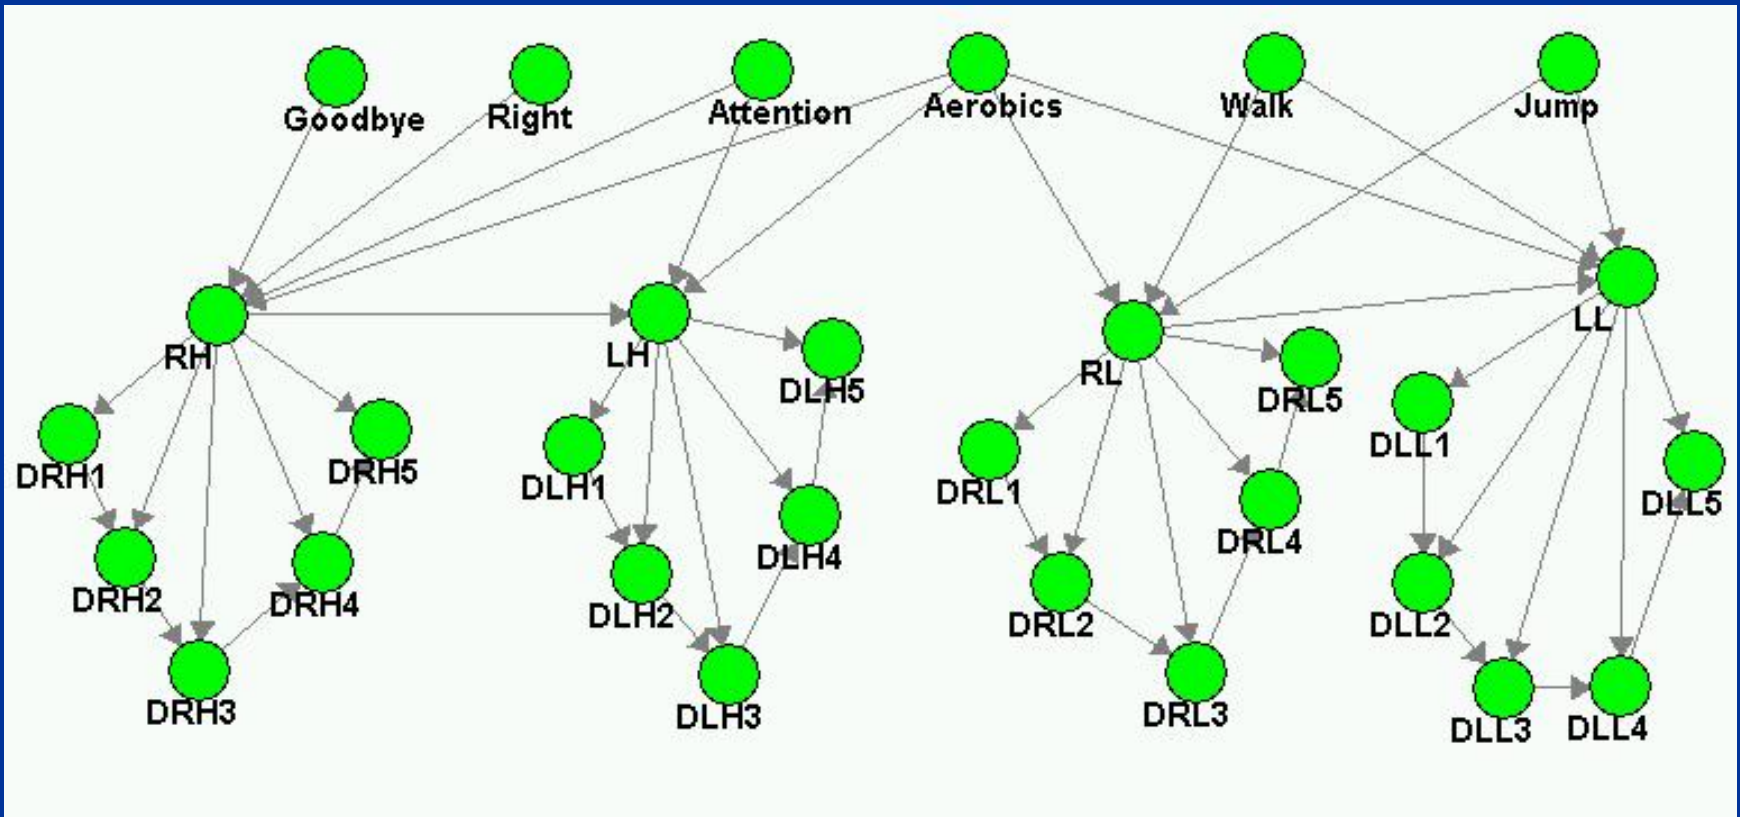
Reconocimiento continuo



Modelo General



RB para reconocimiento



Resultados

- El modelo se entrenó con 150 ejemplos de las 6 actividades
- Se probó con 50 secuencias:
 - 39 correctas
 - 9 indeciso
 - 2 incorrectas


Matriz de Confusión

	Good bye	Rig ht	Wa lk	Attent ion	Ju mp	Aerob ics	Oth er	Indecis ive
Goodbye	3	1					2	1
Right		5		1			1	2
Walk			7				1	1
Attention				4				
Jump					6			
Aerobics						7		
Other							1	
Walk and Attention			4	5			1	
Jump and Attention				2	2			


Reconocimiento de gestos

- Reconocimiento de gestos orientados a comandar robots
- Inicialmente 5 gestos
- Reconocimiento con RBD


Come




attention



go-right



go-left




stop



Extracción de características


- Detección de piel
- Segmentación de cara y mano
- Seguimiento de la mano
- Características de movimiento

Segmentación

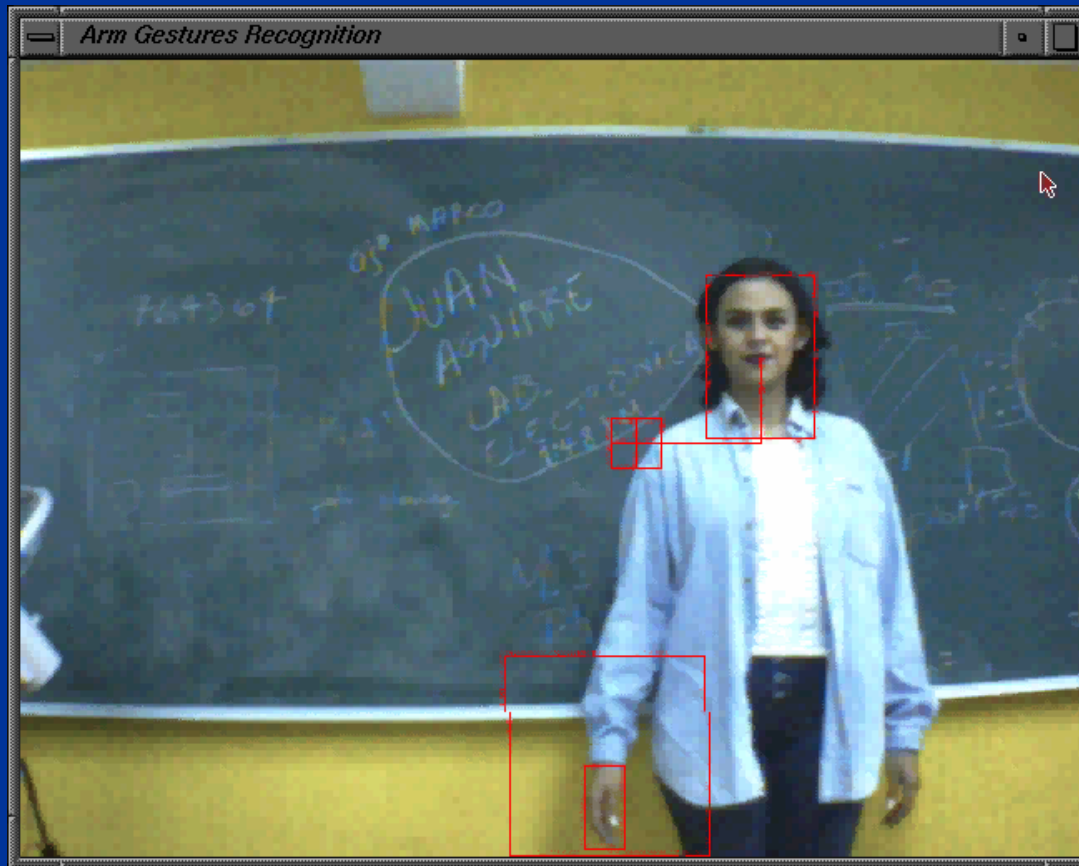


Agrupamiento de píxeles de piel en muestreo radial

Seguimiento




Seguimiento



Entrenamiento y Reconocimiento

- Los parámetros para la RBD se obtienen de ejemplos de cada gesto usando el algoritmo EM
- Para reconocimiento, se obtiene la probabilidad de cada modelo mediante propagación

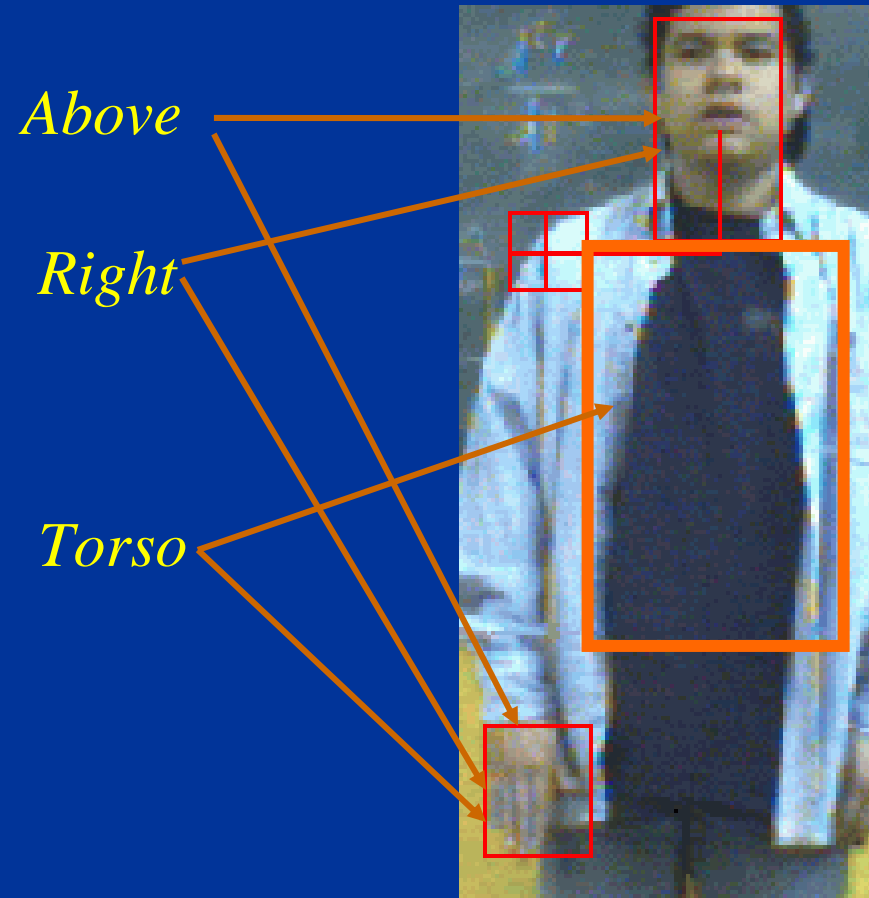
Atributos de Movimiento




Atributos de postura

Relaciones espaciales (binarias) entre la mano y otras partes del cuerpo:

- Derecha
- Arriba
- Torso



Clasificador bayesiano dinámico



Experimentos

- 150 muestras de cada gesto
- Ambiente de laboratorio con condiciones variables de iluminación
- Distancia entre 3.0 m y 5.0 m
- Se varía el número de muestras para entrenamiento

Resultados:

DNBCs sin información de postura

	come	attention	go-right	go-left	stop
come	98 %			2 %	
attention	3 %	87 %	10 %		
go-right			100 %		
go-left				100 %	
stop	4 %	39 %		1 %	56 %


Promedio 87.75 %

Resultados:

DNBCs con información de postura

	come	attention	go-right	go-left	stop
come	100 %				
attention		100 %			
go-right			100 %		
go-left				100 %	
stop	11 %	6 %			83 %

Exactitud vs tamaño de la muestra



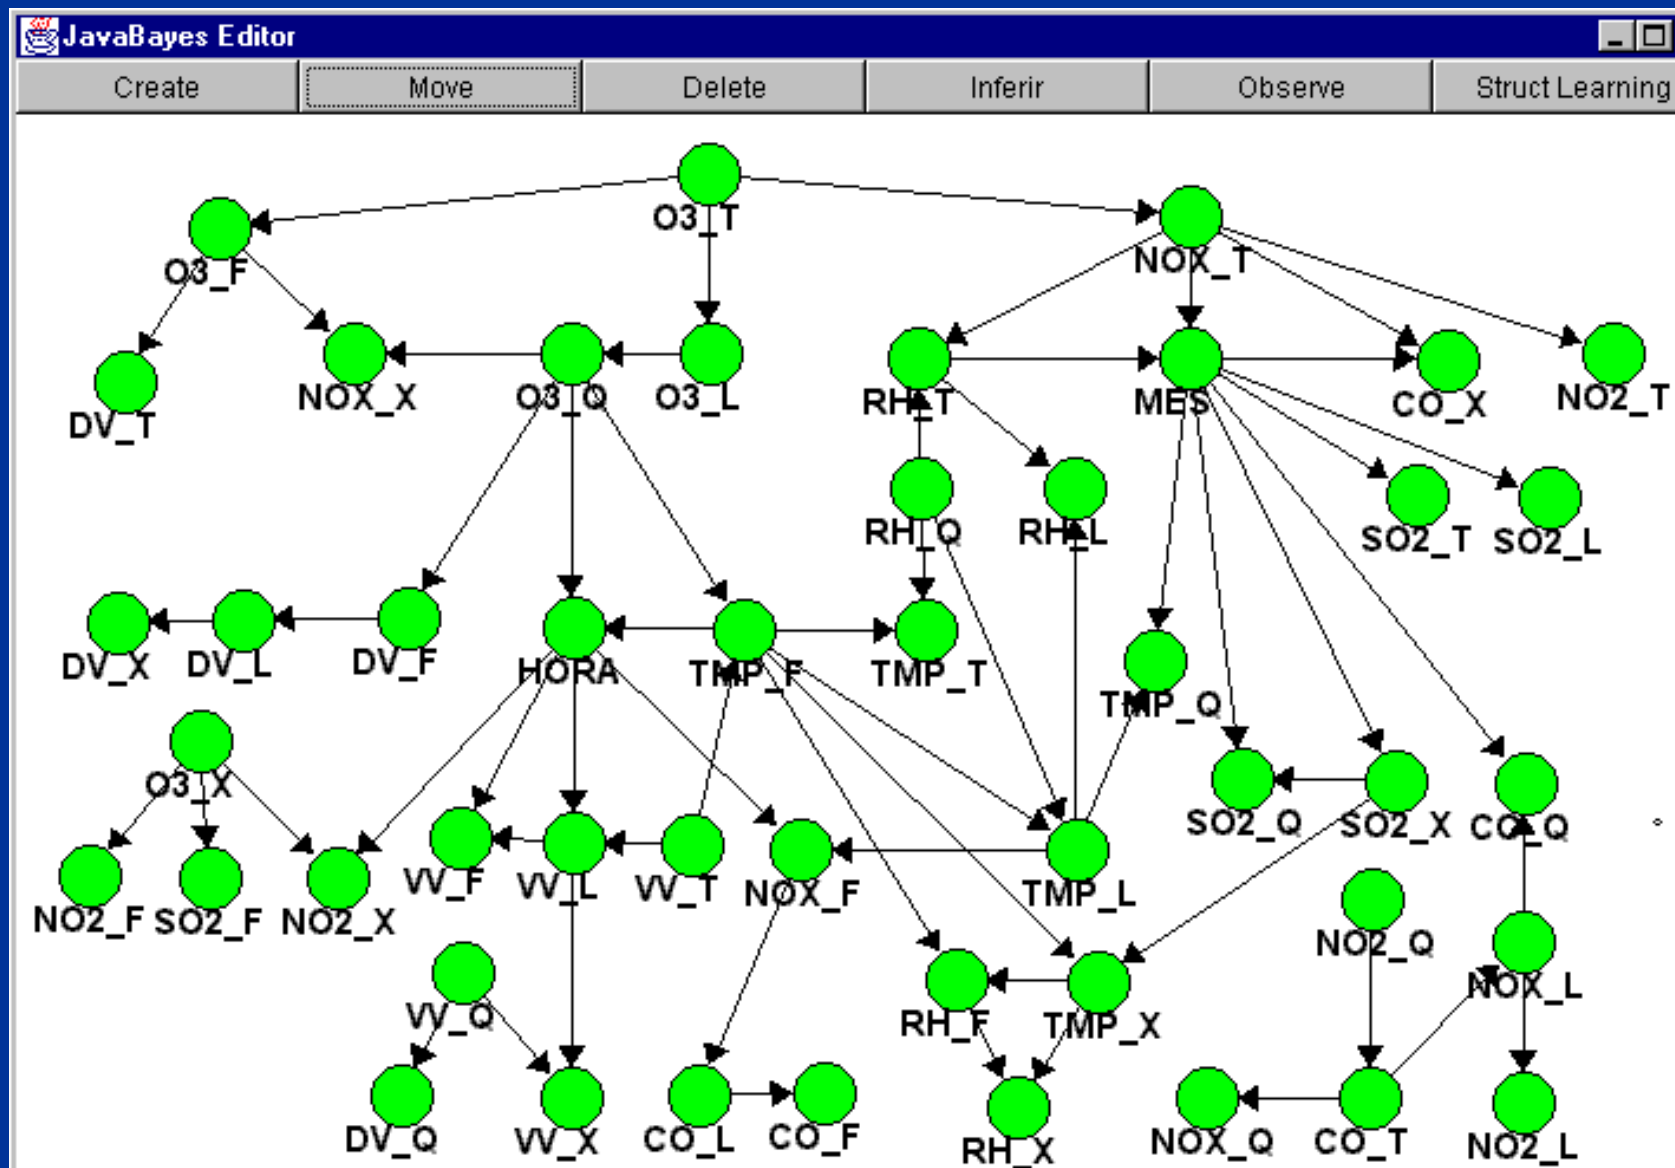
Predicción de Ozono en la Ciudad de México

- Construcción de un modelo basado en redes bayesianas para predecir el Ozono
- 47 variables:
 - 9 mediciones en 5 estaciones
 - Hora del día
 - Mes del año

Experimentos

- Aprendizaje estructural:
 - 400 casos
 - Orden causal
- Predicción:
 - Nivel de ozono en una estación una hora después
 - Diferentes porcentajes de variables conocidas

Modelo



Comparación con una red neuronal

Predicción de ozono: BN vs HNN

% Datos	Método	Error relativo	Error de inter.
100%	BN	21%	12%
	HNN	26%	12%
85%	BN	21%	12%
	HNN	26%	9%
70%	BN	25%	8%
	HNN	32%	12%
50%	BN	21%	12%
	HNN	37%	29%

Otras aplicaciones

- Predicción del precio del petróleo
- Modelado de riesgo en accidentes de automóviles
- Diagnóstico médico
- Validación de sensores
- Modelado de usuarios (ayudantes Microsoft Office)
- Modelado del estudiante (tutores inteligentes)
- Diagnóstico de turbinas (General Electric)
- Reconocimiento de objetos en imágenes
- Reconocimiento de voz
- ...

Referencias

- Variables continuas
 - Pearl cap. 7
 - G. Torres Toledano, E. Sucar, Iberamia 1998
- RB dinámicas
 - U. Kjaerulff, A computational scheme for reasoning in dynamic belief networks, UAI'92
- RB temporales
 - K. Kanazawa, A logic and time nets for probabilistic inference, AAAI'91
 - G. Arroyo, E Sucar, A temporal bayesian networks for diagnosis and prediction, UAI'99

Referencias

- Aplicaciones

- H. Aviles-Arriaga, L.E. Sucar, “Dynamical Bayesian Networks for Visual Recognition of Dynamic Gestures”, *Journal of Intelligent and Fuzzy Systems*, Vol. 12, 243--250, 2002
- R. Díaz de Leon, L.E. Sucar, “Recognition of Continuous Activities”, in Francisco J. Garijo, José C. Riquelme and Miguel Toro (Eds.), *Lecture Notes in Computer Science 2527*, Springer-Verlag, Berlin, 2002, pp. 875—881
- G. Arroyo-Figueroa, L.E. Sucar, A. Villavicencio, “Probabilistic temporal reasoning and its application to fossil power plant operation”, *Expert Systems and Applications*, Vol. 15, No. 3/4, pp. 317-324, Pergamon Press, 1998.
- L. E. Sucar, D. F. Gillies, “Probabilistic Reasoning in High-Level Vision”, *Image and Vision Computing Journal*, Vol. 12(1) (1994) 42-60.
- L. E. Sucar, J. Pérez-Brito, J. C. Ruiz Suárez, “Induction of Dependency Structures from Data and its Application to Ozone Prediction”, *Eight International Conference on Industrial and Engineering Applications of Artificial Intelligence and Expert Systems (IEA/AIE-90)*, Melbourne, Australia, Junio 5-9, 1995.