

# Métodos de Inteligencia Artificial

---

L. Enrique Sucar (INAOE)

[esucar@inaoep.mx](mailto:esucar@inaoep.mx)

[ccc.inaoep.mx/esucar](http://ccc.inaoep.mx/esucar)

Tecnologías de Información

UPAEP

# Redes Bayesianas: Parte III

- Aplicaciones

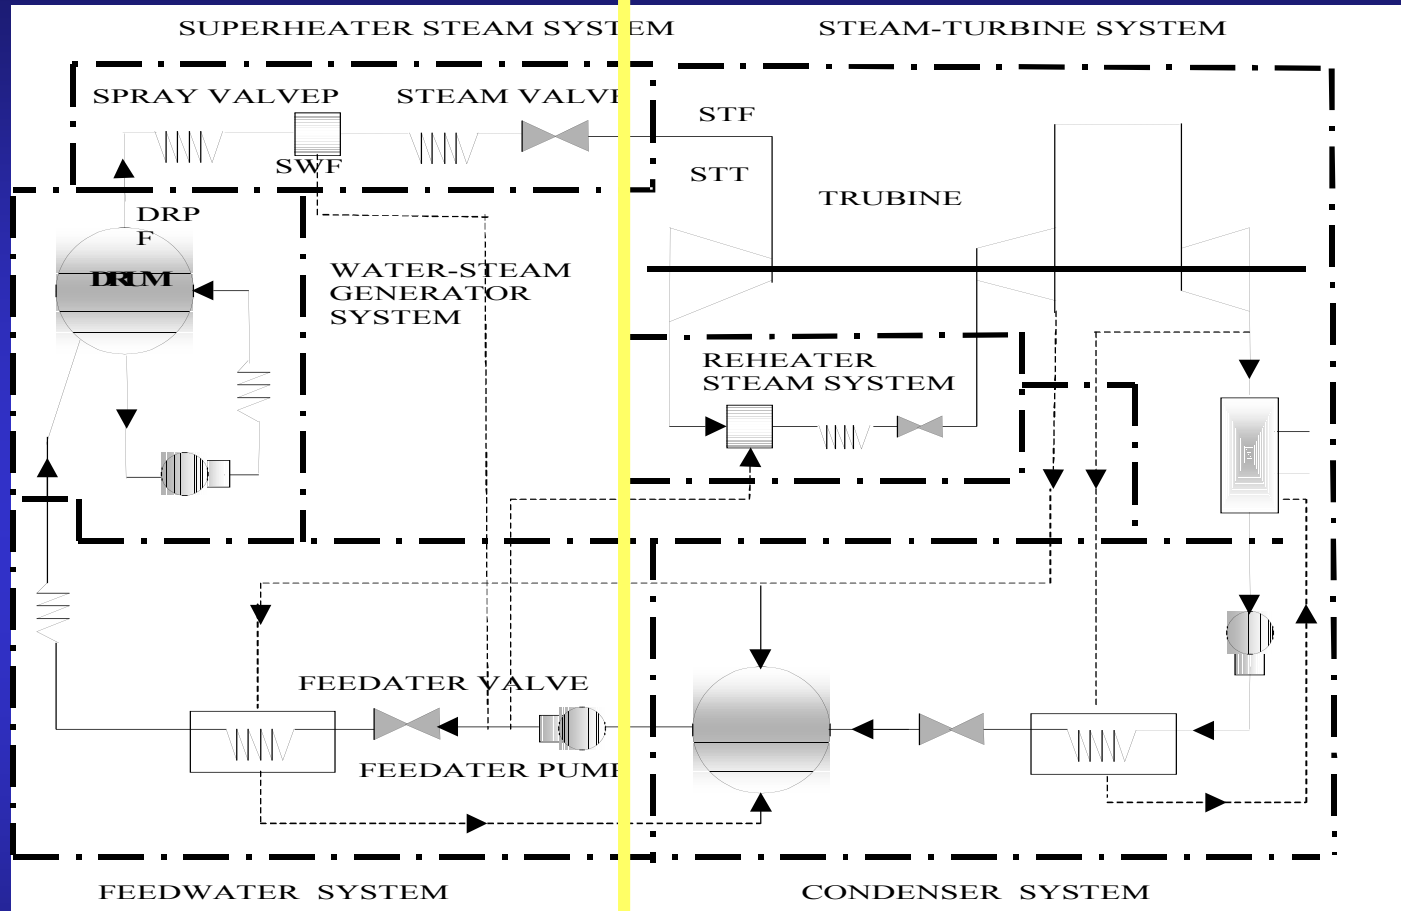
# Aplicaciones

- Diagnóstico de plantas eléctricas
  - Red temporal
- Endoscopia
  - 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)

# Red bayesiana con nodos temporales

## Variables

LI=Load increment

FWPF=FW pump failure

FWVF=FW valve failure

SWVF=SW valve failure

STV=Steam valve

FWP=FW pump

FWV=FW valve

SWV=SW valve

STF=Steam flow

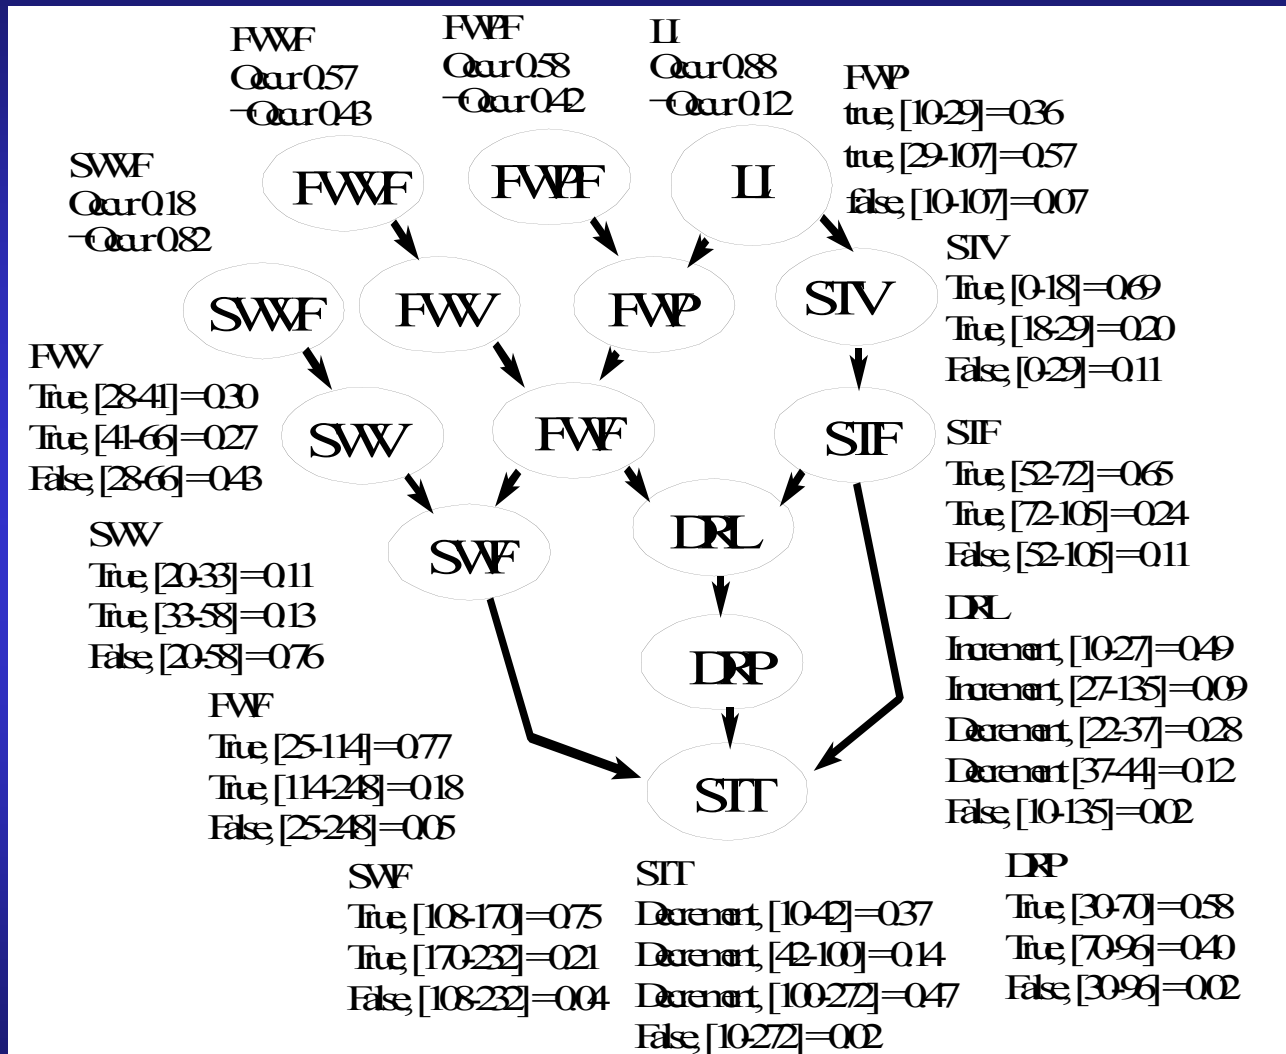
FWF=FW flow

SWF=SW flow

DRL=Drum level

DRP=Drum pressure

STT=Steam temperature



# Resultados Experimentales


Prueba	m	s
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*



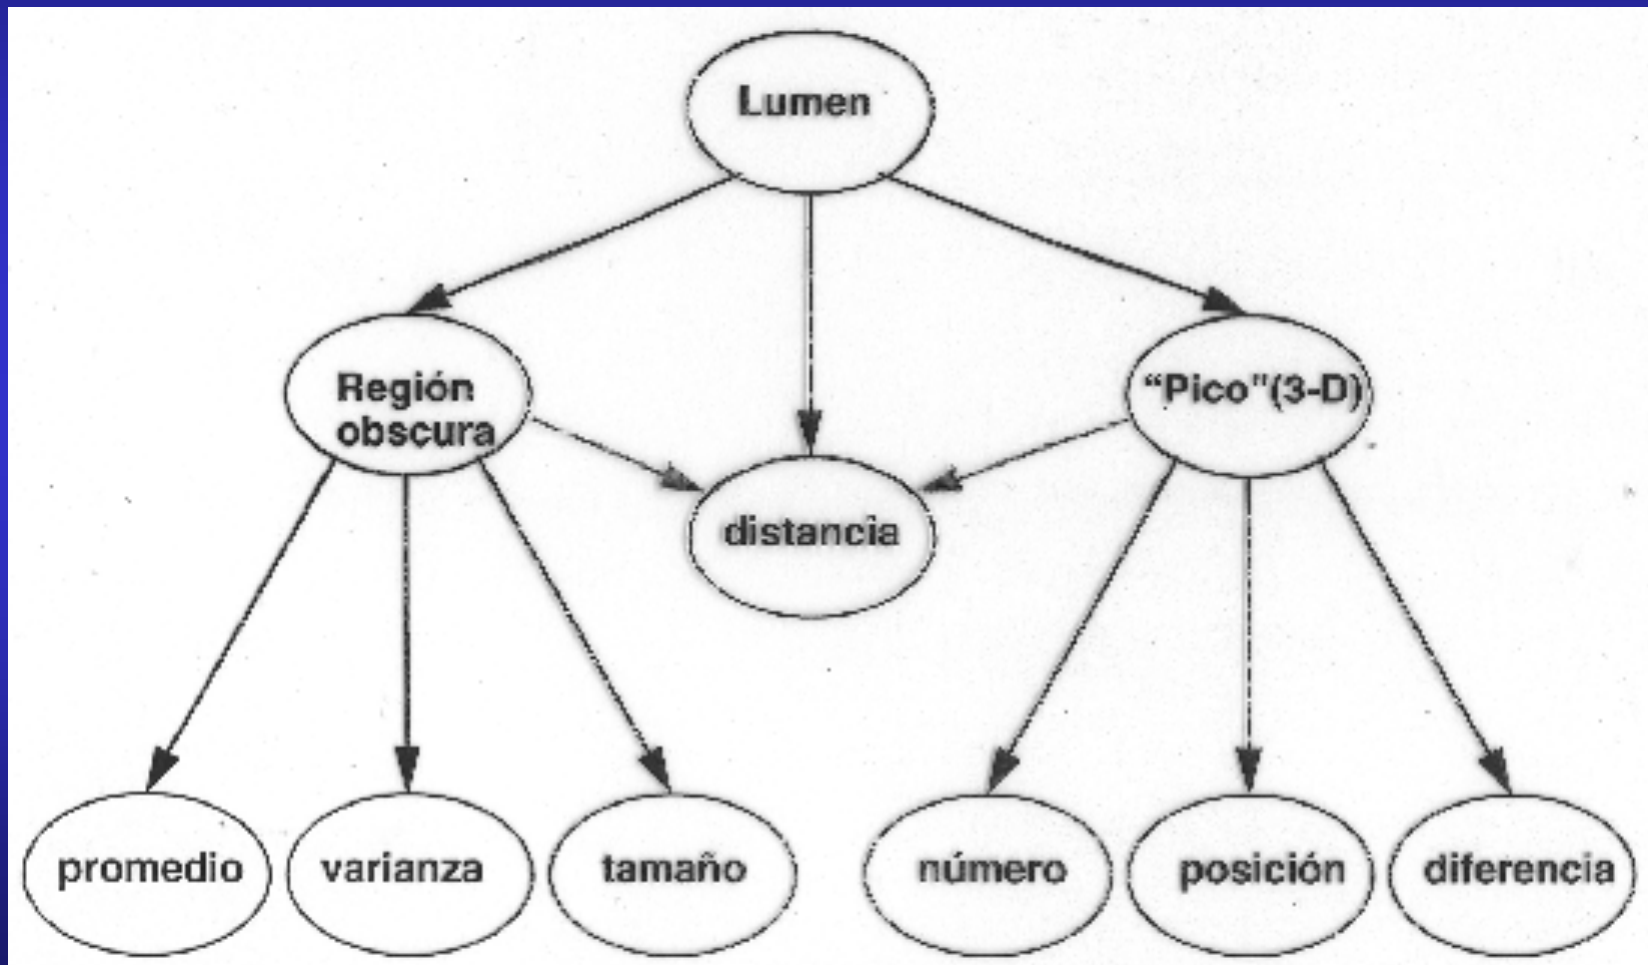
(a) Colon Image



(b) Depth map (needle diagram)



# RB para endoscopía (parcial)



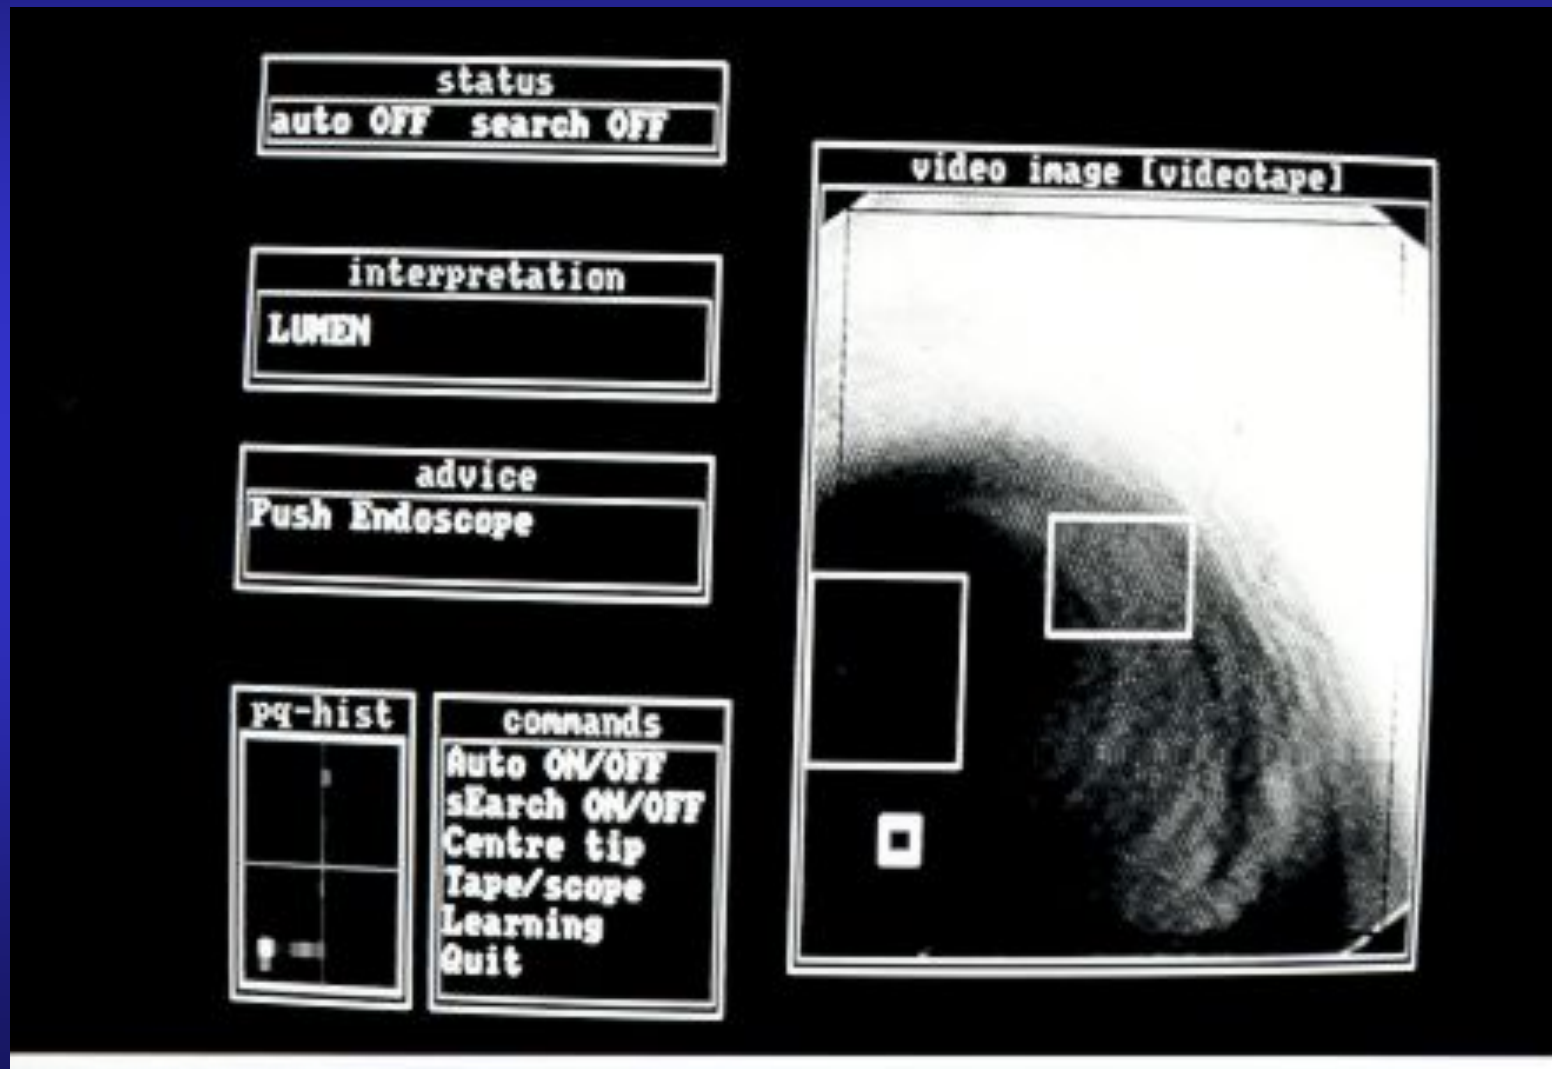
# Metodología

- 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

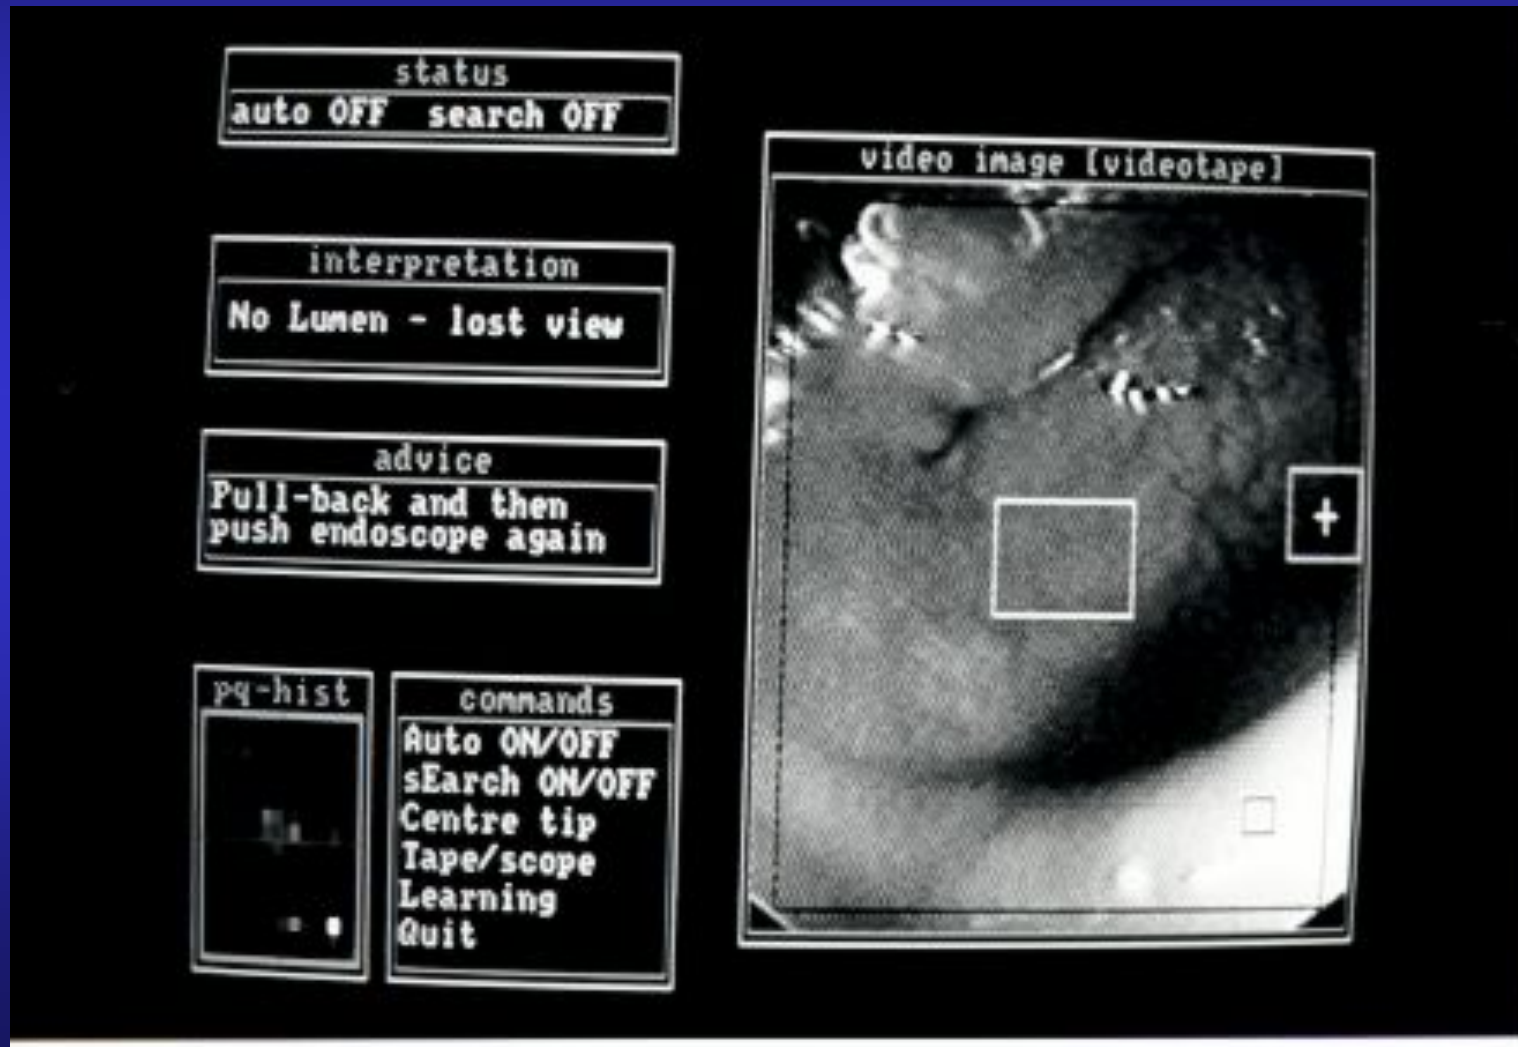


# Sistema de ayuda





# Sistema de ayuda




# 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





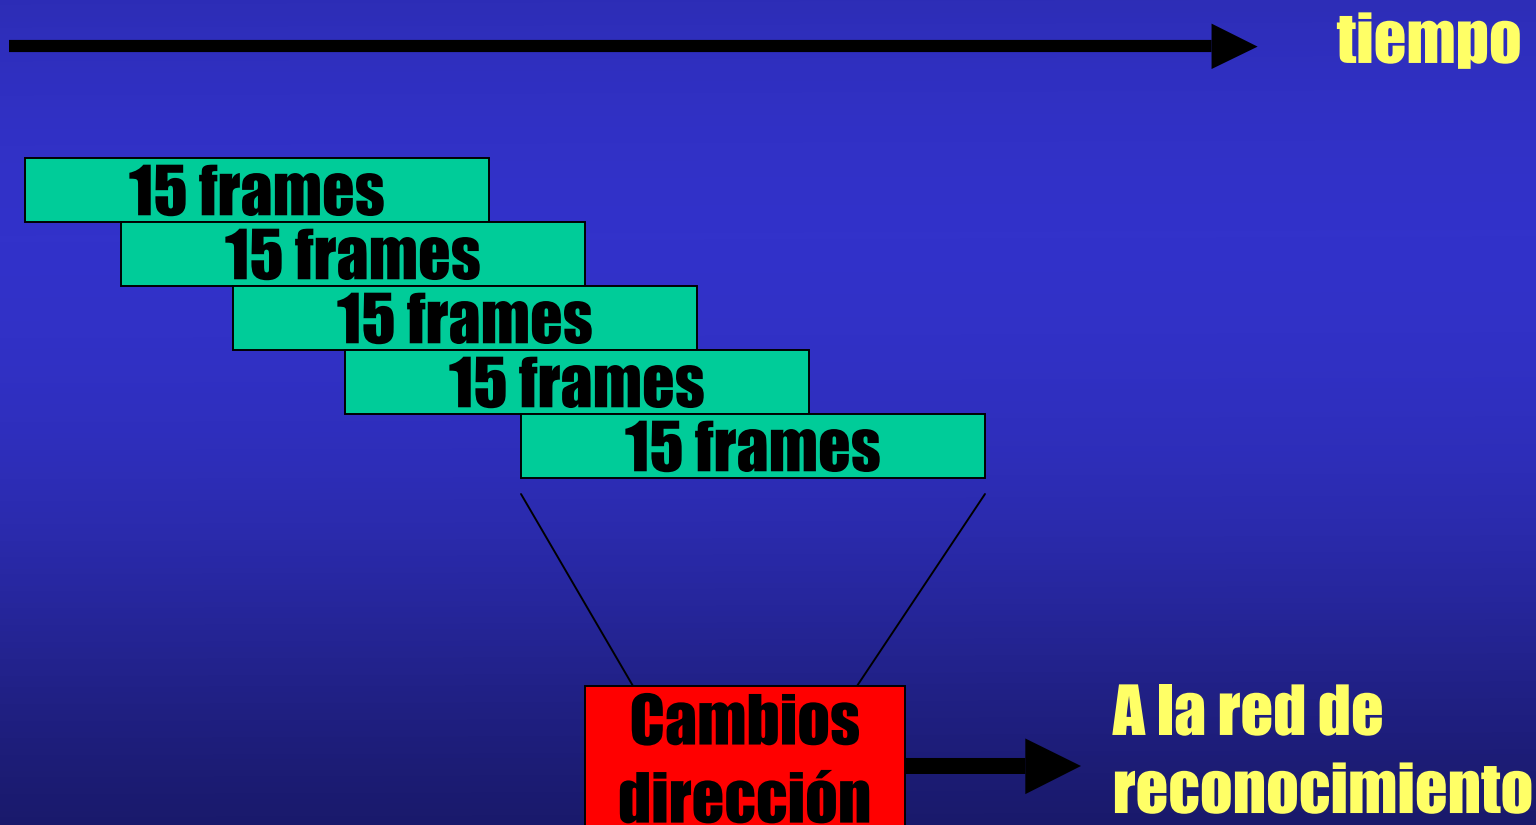
# Parámetros

- 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)

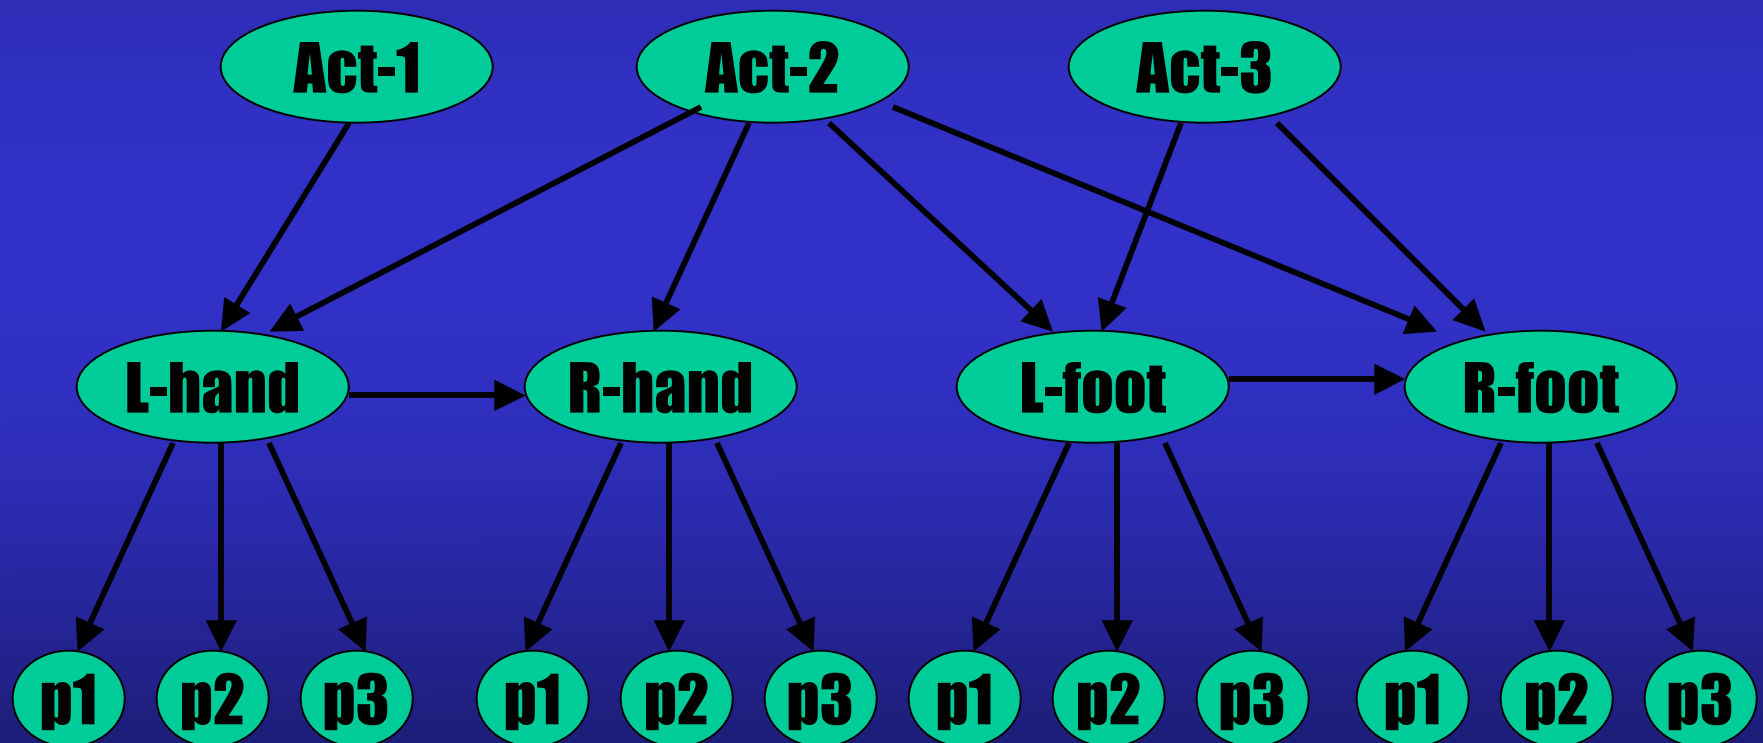
# Modelo para reconocimiento

- 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

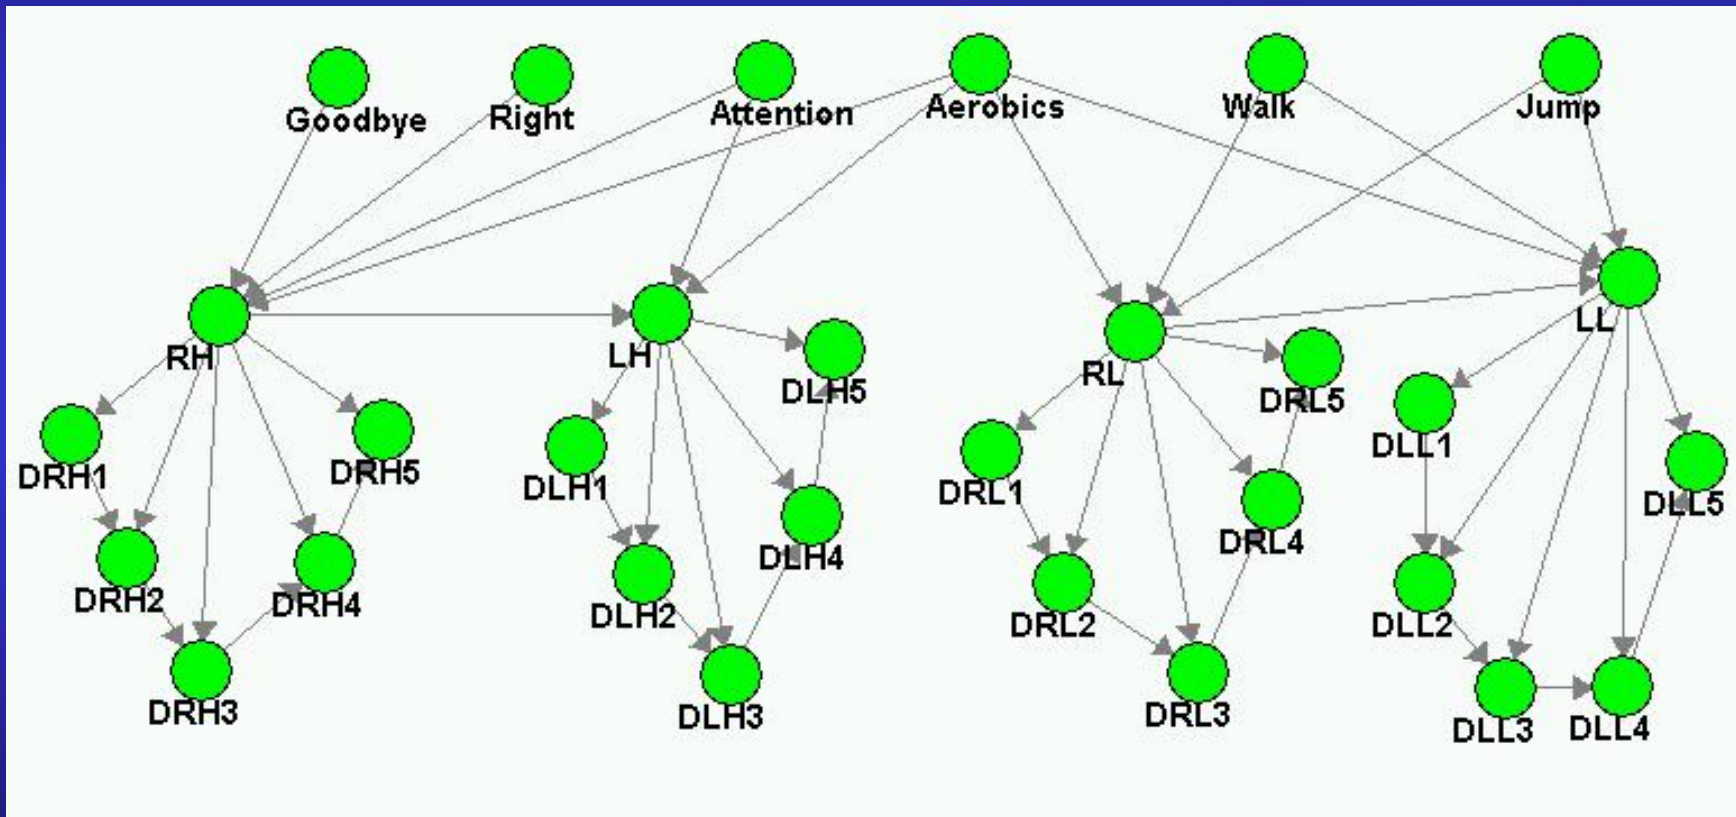
# Reconocimiento continuo



# 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

	<b>Goodbye</b>	<b>Right</b>	<b>Walk</b>	<b>Attention</b>	<b>Jump</b>	<b>Aerobics</b>	<b>Other</b>	<b>Indecisive</b>
<b>Goodbye</b>	3	1					2	1
<b>Right</b>		5		1			1	2
<b>Walk</b>			7				1	1
<b>Attention</b>				4				
<b>Jump</b>					6			
<b>Aerobics</b>						7		
<b>Other</b>							1	
<b>Walk and Attention</b>			4	5			1	
<b>Jump and Attention</b>				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

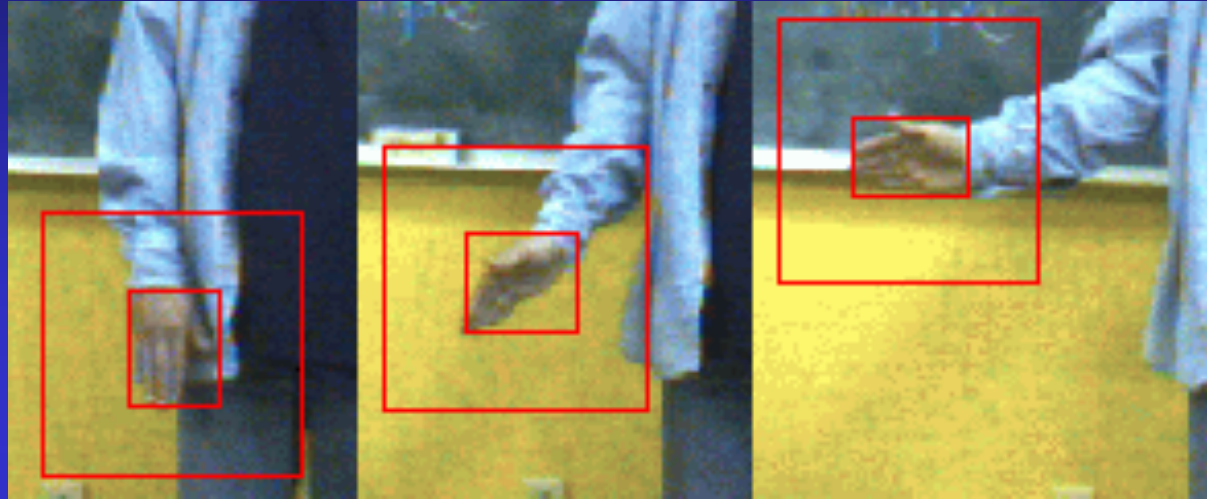
# Segmentación




Agrupamiento de píxeles de piel en muestreo radial



# Seguimiento



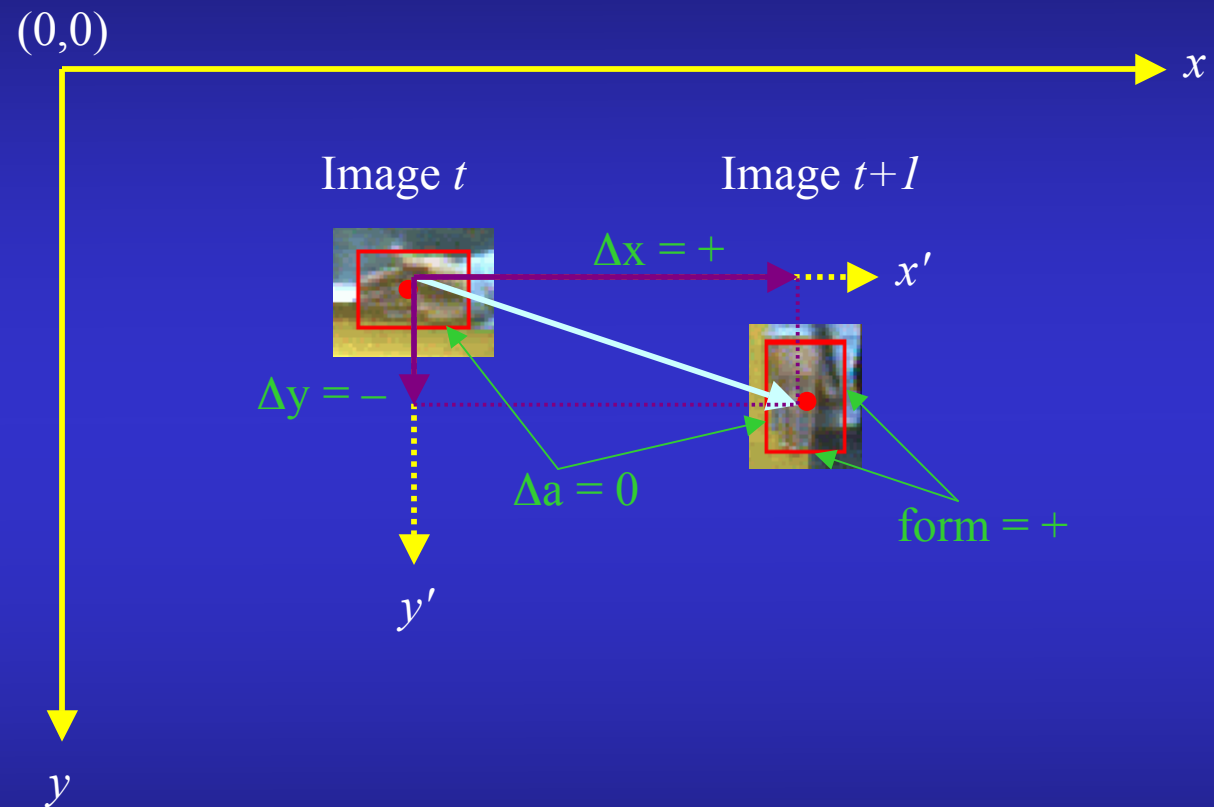
# Seguimiento



# 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

*Above*

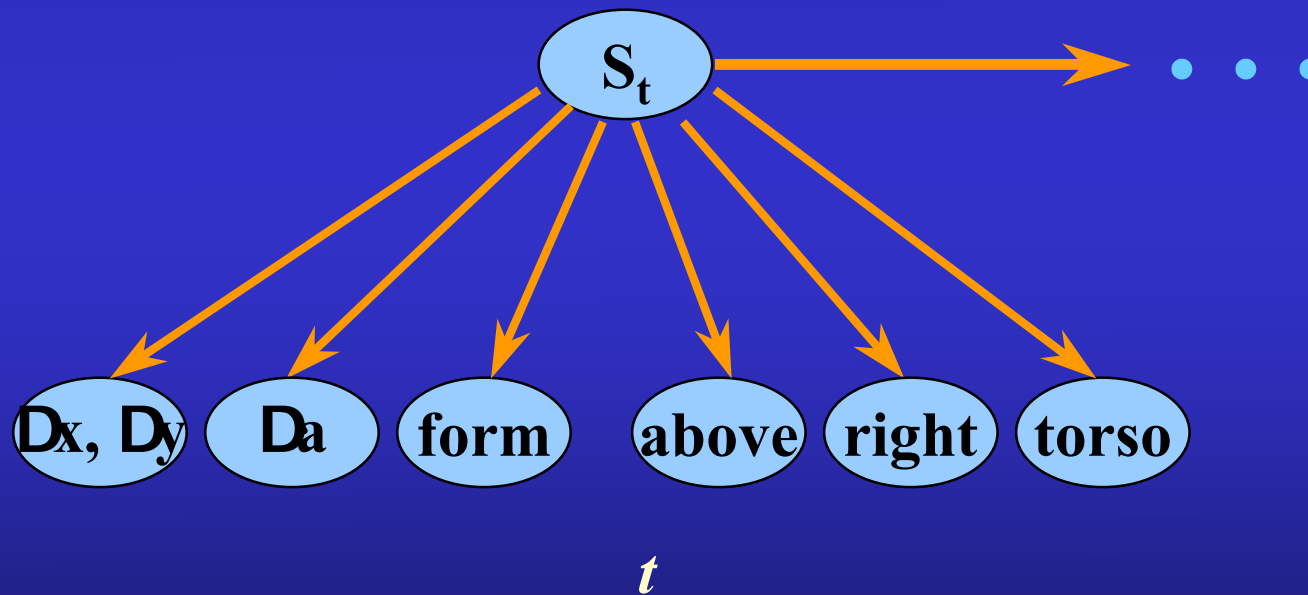
*Right*

*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 %

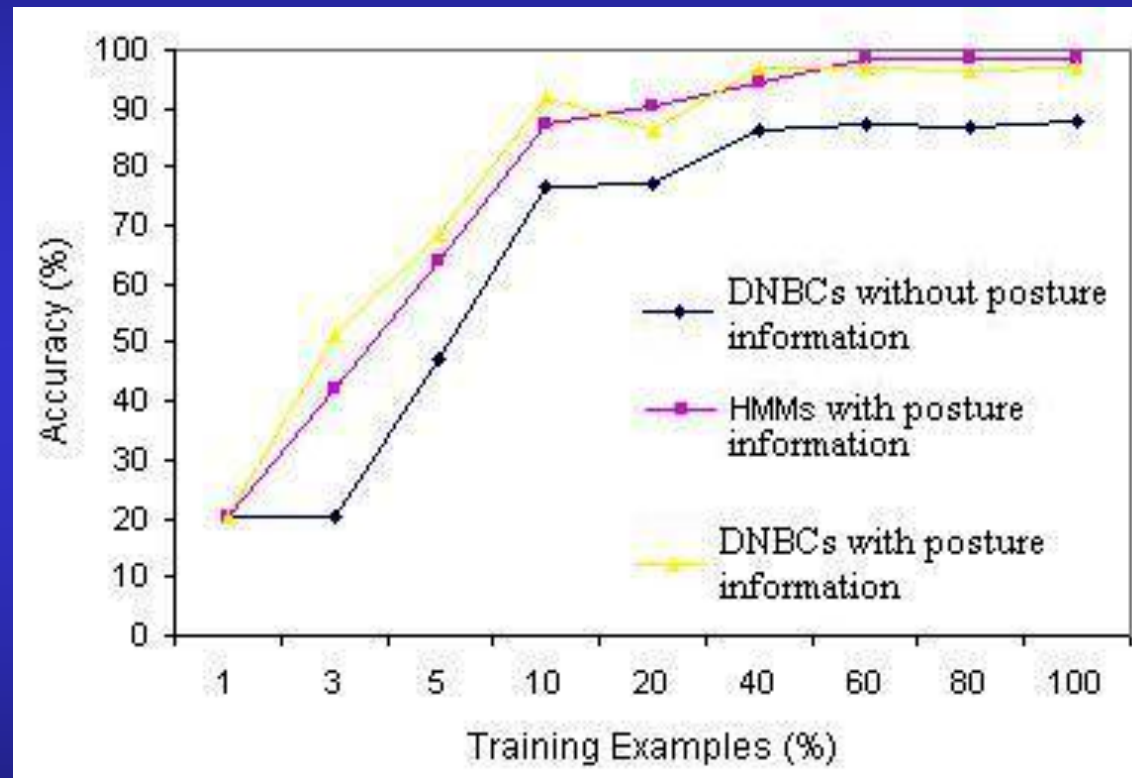
# Resultados:

## 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 %

Promedio 96.75 %

# Exactitud vs tamaño de la muestra



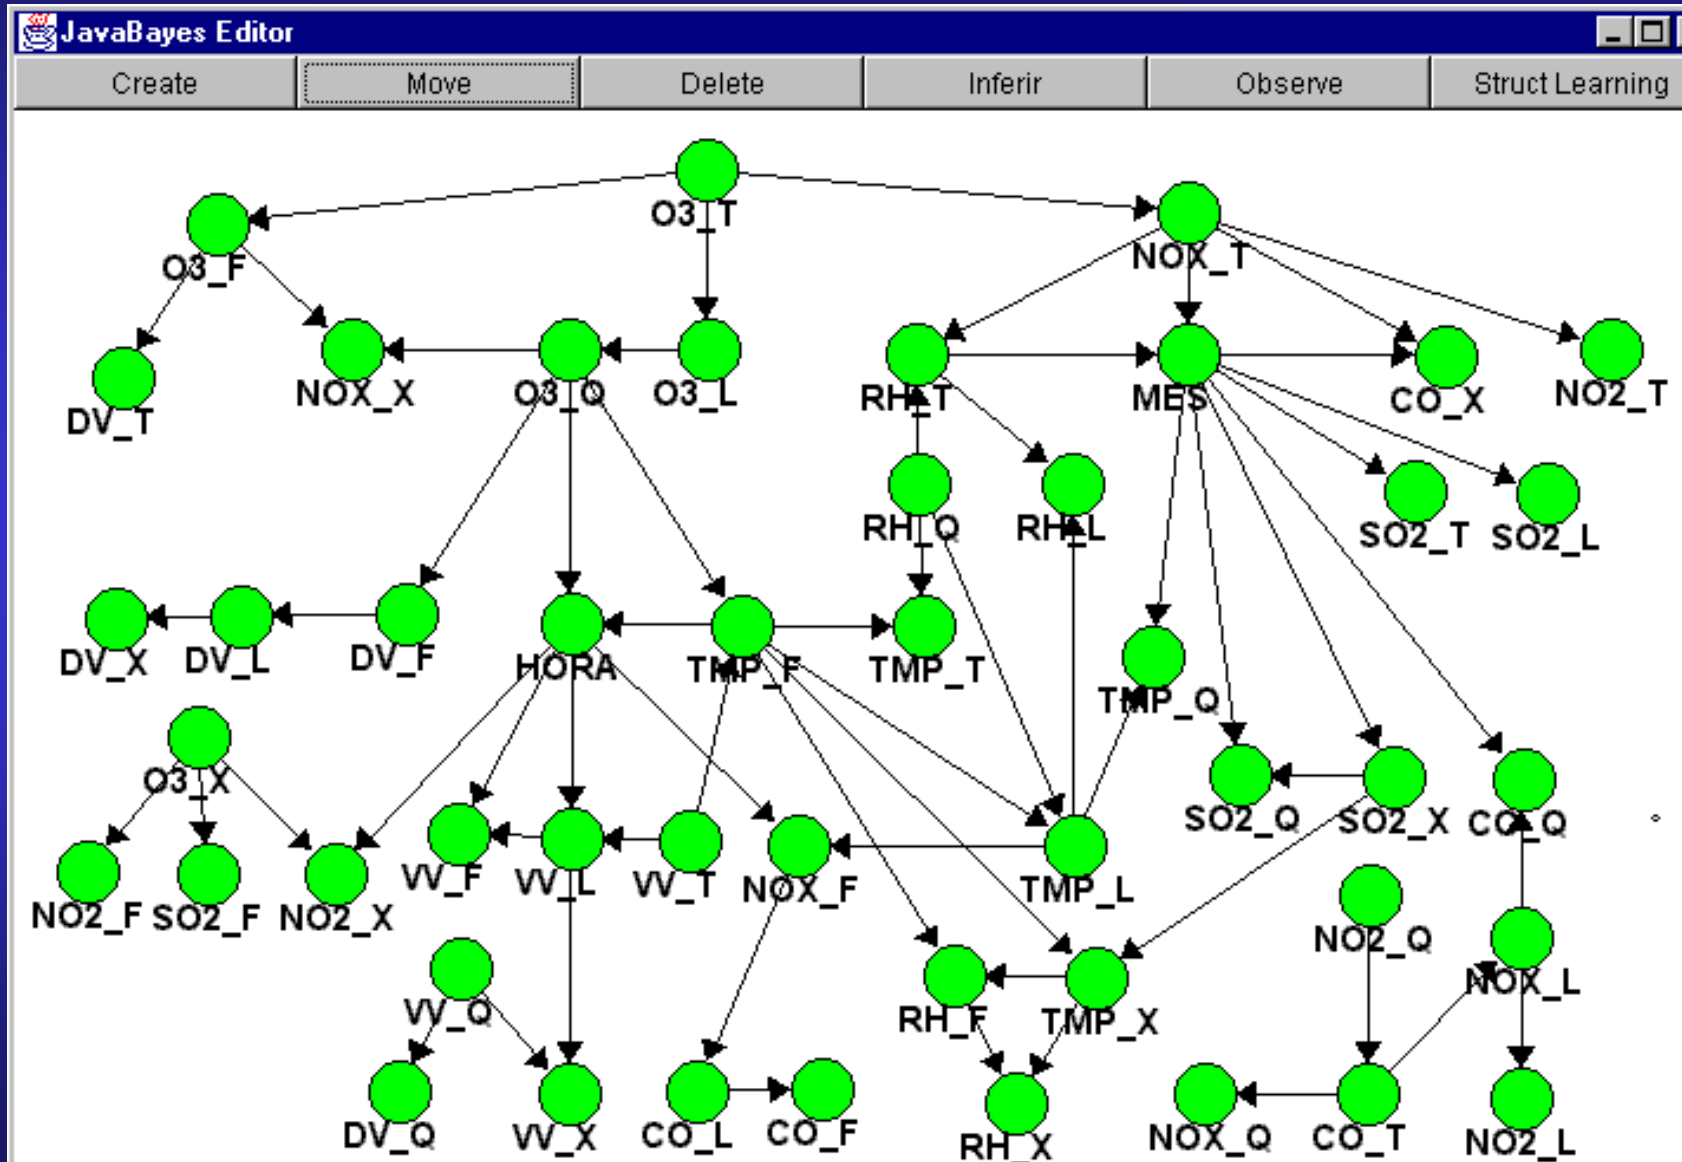
# Predicción de Ozono en la Ciudad de México

- 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
- ...

# Tarea

- Hacer ejercicios para el jueves 10 de marzo
- Examen Parcial - Martes 15 de Marzo
  - Búsqueda
  - Agentes inteligentes
  - Agentes basados en conocimiento: lógica, reglas, representaciones estructuradas
  - Agentes que manejan incertidumbre: redes bayesianas