

# INSTITUTO TECNOLÓGICO Y DE ESTUDIOS SUPERIORES DE MONTERREY



**TECNOLÓGICO  
DE MONTERREY®**

## **“ Reconocimiento Contextual de Gestos para la Toma de Decisiones”**

Presenta:

**José Antonio Montero Valverde**

Sometido al Programa de Graduados en Informática y Computación en  
cumplimiento parcial con los requerimientos para obtener el grado de:

**Doctor en Ciencias Computacionales**

Asesores:

**Dr. Luis Enrique Sucar Succar**

**Dr. Víctor Hugo Zárate Silva**

Cuernavaca, Morelos. Junio de 2007

## Reconocimiento Contextual de Gestos para la Toma de Decisiones

Presentada por:

**José Antonio Montero Valverde**

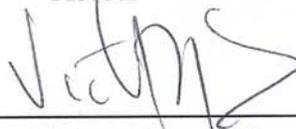
Aprobada por:



---

**Dr. Luis Enrique Sucar Succar**  
Profesor-Investigador del INAOE, Puebla

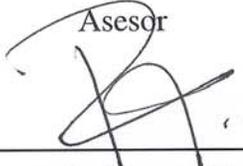
Asesor



---

**Dr. Víctor Hugo Zárate Silva**  
Director del Departamento de Electrónica y Mecatrónica  
ITESM Campus Cuernavaca

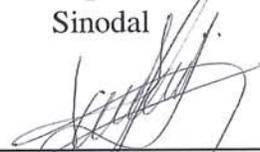
Asesor



---

**Dr. Fernando Ramos Quintana**  
Director del Programa de Graduados en Informática y Computación  
ITESM, Campus Cuernavaca

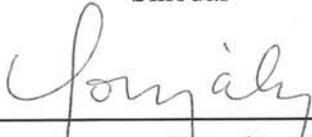
Sinodal



---

**Dr. Raúl Pinto Elías**  
Coordinador de la Especialidad de Inteligencia Artificial  
CENIDET, Cuernavaca, Mor.

Sinodal



---

**Dr. Hugo Gustavo González Hernández**  
Director de la Carrera de Ingeniería Mecatrónica  
Escuela de Ingeniería y Arquitectura, ITESM Campus Puebla

Sinodal

*A María de los Ángeles y José Antonio*

*Quienes han cambiado mi percepción del mundo y me inspiran a perseguir nuevos sueños.*

## AGRADECIMIENTOS

A mis asesores de tesis. Dr. Luis Enrique Sucar Succar, le estoy verdaderamente agradecido porque gracias a su experiencia y acertada guía logré concluir este proyecto tanto tiempo esperado. Asimismo, agradezco al Dr. Víctor H. Zárate Silva su valioso apoyo durante la realización de este trabajo.

Agradezco al pueblo de México que paga impuestos, porque gracias a este aporte se han generado iniciativas gubernamentales a través de programas institucionales que apoyan la formación de profesionistas a diferentes niveles académicos. Por tal motivo, agradezco el apoyo económico y el tiempo asignado para realizar mi estudio doctoral a las siguientes instituciones:

Sistema Nacional de Educación Superior Tecnológica (SNEST).

Dirección General de Educación Superior Tecnológica (DGEST -antes DGIT-).

Asociación Nacional de Universidades e Instituciones de Educación Superior (ANUIES) por el programa SUPERA.

Consejo del Sistema Nacional de Educación Tecnológica (CoSNET -institución ya desaparecida-).

A mis revisores de tesis: Dr. Fernando Ramos Quintana, Dr. Raúl Pinto Elías, Dr. Hugo González Hernández, agradezco sus valiosas observaciones para enriquecer este trabajo.

Deseo expresar mi agradecimiento al personal académico y administrativo del Tecnológico de Monterrey Campus Cuernavaca por su trato siempre amable.

A mis compañeros de clases: Manuel Zapata, Mario Limón, Felipe Verdalet, Rafael Rivera, Miriam Martínez, les agradezco los gratos momentos que compartimos durante nuestro paso por esta gran experiencia. A Miriam Martínez, le agradezco los momentos de apoyo que compartimos sobretodo en la última fase de este proyecto donde hubo instantes en los que no se vislumbraba la luz al final del túnel. De antemano, pido disculpas si omití mencionar a alguien en este breve espacio.

De forma muy especial agradezco a mi esposa María de los Ángeles y a mi hijo José Antonio su coraje y comprensión por permitir ausentarme temporalmente de sus vidas y poder dar inicio a este sueño, les estaré siempre agradecido por estar a mi lado cuando los necesito y compartir los momentos más importantes de mi vida.

*A todos ustedes ¡¡Muchas Gracias!!*

# Resumen

Dentro del amplio rango de actividades humanas, los gestos realizados con las manos al interactuar con objetos del entorno ocupan un lugar importante en la vida cotidiana. Así que el diseño de sistemas automáticos que reconozcan de manera confiable tales gestos es un área de investigación relevante. Sin embargo, es aún más interesante saber *qué hacer con los gestos reconocidos*, ya que permite incorporar en los sistemas automáticos, aspectos como la toma de decisiones. En esta tesis, se propone un nuevo modelo computacional que integra técnicas de visión computacional y teoría de decisiones con el fin de reconocer los gestos manipulativos realizados por una persona en escenarios conocidos y tomar acciones al respecto. Este modelo puede aplicarse en escenarios donde sea necesario tomar decisiones inmediatas a partir de la observación visual del comportamiento humano, tales como: videoconferencias y apoyo a discapacitados. La adaptabilidad del modelo en diferentes escenarios se realiza con ligeras modificaciones. Para esto el sistema se estructura en dos módulos: i) Módulo de reconocimiento de gestos, el cual combina información de movimiento y de contexto bajo un nuevo enfoque y, ii) Módulo para la toma de decisiones, el cual propone un nuevo esquema basado en redes de decisión dinámica para tomar decisiones en problemas de decisión de Markov parcialmente observables con un horizonte finito. El módulo de reconocimiento de gestos se basa en información de movimiento (trayectorias del centroide de la mano) y de contexto (color y posición relativa de objetos) para entrenar modelos ocultos de Markov (HMMs) y representar los distintos gestos realizados en un escenario. La incorporación de información contextual proporciona resultados experimentales de reconocimiento promedio de gestos que van desde 94 % hasta 99,57 % en distintos escenarios. Esto representa un incremento significativo en el proceso de reconocimiento de gestos comparado al resultado obtenido cuando no se integra el contexto. El módulo para la toma de decisiones utiliza una red de decisión dinámica donde se maneja el aspecto de incertidumbre en los estados a través de una red bayesiana dinámica. La mejor alternativa se selecciona bajo el enfoque de máxima utilidad esperada. Para esto se consideran los posibles resultados de cada acción a través de futuras etapas temporales y la creencia acerca del gesto más probable realizado por el usuario. Este modelo fué implementado en dos distintos escenarios para su evaluación: Videoconferencias y Apoyo a personas para completar tareas. La evaluación realizada en ambos escenarios fué subjetiva a través de una encuesta realizada a los usuarios potenciales. Los resultados experimentales obtenidos de la evaluación son satisfactorios, indicando que el rendimiento y eficiencia del modelo desarrollado resultan adecuados para aplicarse en diferentes ambientes reales.

# Índice general

<b>Índice de figuras</b>	<b>X</b>
<b>Índice de tablas</b>	<b>XIV</b>
<b>1. Introducción</b>	<b>1</b>
1.1. Tipos de gestos . . . . .	1
1.2. Teoría de decisiones . . . . .	3
1.3. Objetivo de la tesis . . . . .	4
1.4. Metas . . . . .	4
1.5. Alcances . . . . .	4
1.6. Metodología . . . . .	5
1.6.1. Descripción de componentes . . . . .	5
1.6.2. Resultados obtenidos . . . . .	7
1.7. Contribuciones . . . . .	8
1.8. Organización de la tesis . . . . .	9
<b>2. Reconocimiento de gestos humanos</b>	<b>10</b>
2.1. Introducción . . . . .	10
2.2. Reconocimiento de gestos sin aplicar contexto . . . . .	11
2.3. Reconocimiento de gestos utilizando contexto . . . . .	16
2.4. Reconociendo la interacción humana . . . . .	18
2.5. La utilidad de los gestos . . . . .	22
2.6. Resumen del capítulo . . . . .	23

<b>3. Procesos de Decisión de Markov</b>	<b>25</b>
3.1. Procesos de decisión de Markov . . . . .	25
3.2. Procesos de decisión de Markov parcialmente observables . . . . .	27
3.3. Redes bayesianas dinámicas . . . . .	30
3.3.1. Redes bayesianas . . . . .	30
3.3.2. Redes bayesianas dinámicas . . . . .	31
3.4. Redes de decisión . . . . .	32
3.4.1. Evaluación de la red de decisión . . . . .	33
3.4.2. MDP de horizonte finito . . . . .	34
3.5. Redes de decisión dinámicas . . . . .	36
3.6. Resumen del capítulo . . . . .	37
<b>4. Reconocimiento de gestos utilizando contexto</b>	<b>38</b>
4.1. Información contextual utilizada . . . . .	38
4.2. Detección y seguimiento de la mano de una persona . . . . .	39
4.2.1. Modelo de color utilizado . . . . .	39
4.2.2. Segmentación basada en movimiento . . . . .	41
4.2.3. Combinando color y movimiento . . . . .	43
4.2.4. Seguimiento de las manos de una persona . . . . .	45
4.3. Extracción y representación de características . . . . .	47
4.3.1. Discretización de las características . . . . .	52
4.4. Reconocimiento de gestos usando HMMs . . . . .	53
4.4.1. Definición . . . . .	54
4.4.2. Vectores de observación . . . . .	56
4.4.3. Datos de entrenamiento . . . . .	57
4.4.4. Entrenamiento de los HMMs . . . . .	58
4.4.5. Reconocimiento de gestos . . . . .	59
4.5. Reconocimiento de objetos . . . . .	59
4.6. Reconocimiento de gestos utilizando contexto . . . . .	64

4.7. Pruebas experimentales . . . . .	66
4.8. Resumen del capítulo . . . . .	69
<b>5. Integrando información visual y teoría de decisiones</b>	<b>71</b>
5.1. Introducción . . . . .	71
5.2. Representación de la RDD . . . . .	73
5.3. Etapas del modelo . . . . .	74
5.4. Especificación del modelo . . . . .	78
5.4.1. Descripción de escenarios . . . . .	78
5.5. Resumen del capítulo . . . . .	83
<b>6. Evaluación del modelo</b>	<b>85</b>
6.1. Introducción . . . . .	85
6.2. Criterios de evaluación . . . . .	86
6.2.1. Tiempo de respuesta . . . . .	86
6.2.2. Confiabilidad al seleccionar la mejor alternativa . . . . .	88
6.2.3. Selección de la RDD utilizada . . . . .	92
6.2.4. Comparación del modelo contra un operador humano . . . . .	94
6.3. implementación . . . . .	103
6.4. Resumen de capítulo . . . . .	103
<b>7. Conclusiones</b>	<b>105</b>
7.1. Resumen . . . . .	105
7.2. Aportaciones . . . . .	107
7.3. Trabajo futuro . . . . .	108
<b>Referencias</b>	<b>117</b>
<b>A. Selección de características</b>	<b>118</b>
<b>B. Especificación de la red de decisión dinámica utilizada</b>	<b>129</b>

B.1. Videoconferencia . . . . .	129
B.2. Apoyo a discapacitados . . . . .	132

# Índice de figuras

1.1.	Diagrama de bloques del modelo desarrollado. . . . .	6
2.1.	Secuencia de imágenes que muestran la trayectoria descrita por la cabeza de una persona al pararse [64]. . . . .	11
2.2.	Enfoque utilizado por Ali [2] para reconocer gestos. . . . .	12
2.3.	Imágenes utilizadas por Kim y otros [56] . . . . .	13
2.4.	Historia de movimiento acumulado . . . . .	14
2.5.	Gesto de abrir/cerrar gabinete [97] . . . . .	15
2.6.	Imágenes que ilustran los <i>instantes clave</i> empleados por Ayers [5] . . . . .	17
2.7.	Imagen que ilustra el escenario utilizado por Thonnat [108]. . . . .	19
2.8.	Objetos reconocidos por Darnell [76]. . . . .	20
2.9.	Imagen que muestra una vista superior del escenario empleado por Darnell . . . . .	21
2.10.	Imágenes que muestra el escenario utilizado por Fritsh [31] . . . . .	22
3.1.	Un proceso de decisión de Markov modela la interacción entre el sistema y el mundo. . . . .	26
3.2.	vista geométrica de la función de valor. . . . .	29
3.3.	Red bayesiana dinámica analizada en dos etapas de tiempo $t$ y $t + 1$ . . . . .	32
3.4.	Estructura básica de una red de decisión. . . . .	33
3.5.	Red de decisión representando a un MDP de horizonte finito . . . . .	35
3.6.	Estructura de una red de decisión dinámica . . . . .	36
4.1.	Proceso de detección de una persona . . . . .	40
4.2.	Uso de modelos de color para detectar piel . . . . .	42
4.3.	Proceso de segmentación basado en movimiento . . . . .	43

4.4. Segmentación basada en color y movimiento . . . . .	44
4.5. Diagrama de flujo del algoritmo CamShift [16] el cual es aplicado en el seguimiento.	46
4.6. Proceso de seguimiento de la mano. . . . .	48
4.7. Trayectoria de un gesto . . . . .	50
4.8. Descripción de la trayectoria . . . . .	50
4.9. Proceso de cuantización vectorial aplicando el algoritmo <i>k-medias</i> [38] . . . . .	54
4.10. Cadena de Markov . . . . .	54
4.11. HMM-Mostrando las probabilidades de transición y de salida. . . . .	55
4.12. Determinación del número de datos de entrenamiento. . . . .	58
4.13. Reconocimiento de gestos utilizando orientación y magnitud polares . . . . .	60
4.14. Diagrama que ilustra el proceso de detección, localización y seguimiento de objetos.	61
4.15. Detección de objetos en dos escenarios. . . . .	63
4.16. Distancia relativa entre mano y objetos . . . . .	63
4.17. Detección del traslape entre mano y objeto . . . . .	64
4.18. Manipulación del <i>mouse</i> . . . . .	65
4.19. Porcentaje de reconocimiento al integrar contexto . . . . .	67
5.1. POMDP representado como una red de decisión dinámica . . . . .	73
5.2. Procedimiento utilizado para tomar acciones basada en una RDD. . . . .	75
5.3. Etapas de tiempo analizadas para tomar una acción. . . . .	77
5.4. Proceso para seleccionar la mejor vista en videoconferencias. . . . .	77
5.5. Escenario de video conferencias utilizado . . . . .	79
5.6. Consistencia en la información manejada por el sistema, ejemplo 1. . . . .	80
5.7. Consistencia en la información manejada por el sistema, ejemplo 2. . . . .	80
5.8. Secuencia de pasos para completar la tarea asearse las manos. . . . .	82
6.1. Grafo de tareas. . . . .	89
6.2. Gráfica que muestra la variación de las creencias del modelo en el escenario de videoconferencias . . . . .	90

6.3. Gráfica que muestra la variación de las creencias del modelo en el escenario de apoyo a discapacitados . . . . .	91
6.4. Imagen que ilustra el comportamiento del modelo al variar los valores de utilidad . . . . .	92
6.5. Imagen que ilustra el comportamiento del modelo al variar los objetivos (valor de las utilidades) . . . . .	93
6.6. Tiempo en que se obtiene la máxima utilidad esperada. . . . .	94
6.7. Gráfica que muestra una disminución del nodo de valor. . . . .	95
6.8. Efectos del factor de descuento en el cálculo de la utilidad. . . . .	95
6.9. Interfaz para el operador humano . . . . .	97
6.10. Evaluación del escenario de video conferencia. . . . .	100
6.11. Evaluación del escenario de apoyo a discapacitados. . . . .	103
A.1. Diagrama de flujo para la selección de características. . . . .	119
A.2. Código de cadena en coordenadas cartesianas. . . . .	120
A.3. Reconocimiento de gestos al utilizar todas las características combinadas . . . . .	122
A.4. Reconocimiento de gestos al utilizar la característica: posición $x$ . . . . .	123
A.5. Reconocimiento de gestos al utilizar la característica: posición $y$ . . . . .	123
A.6. Reconocimiento de gestos al utilizar como características el código de cadena ( $cc$ ). . . . .	124
A.7. Reconocimiento de gestos al utilizar la característica $\phi$ . . . . .	124
A.8. Uso de la característica: magnitud ( $\rho$ ) en coordenadas polares. . . . .	125
A.9. Uso de la velocidad cartesiana como característica. . . . .	125
A.10. Uso de las características orientación $\phi$ y velocidad cartesiana $v$ . . . . .	126
A.11. Características utilizadas: orientación ( $\phi$ ) y magnitud ( $\rho$ ) en coordenadas polares . . . . .	127
A.12. Características utilizadas: magnitud polar ( $\rho$ ) y velocidad ( $v$ ) cartesiana . . . . .	127
A.13. Reconocimiento de gestos al utilizar las características $\rho\phi v$ . . . . .	128
A.14. Características utilizadas: $\rho, \phi, x$ . . . . .	128
B.1. RDD utilizada en el escenario de videoconferencia. . . . .	130
B.2. RDD mostrando los valores correspondientes de la tabla de utilidad. . . . .	131
B.3. Matriz de transición utilizada por la RDD aplicada en el escenario de videoconferencia. . . . .	132

B.4. RDD utilizada en el escenario de apoyo a discapacitados . . . . . 133

B.5. Tabla de utilidades del escenario apoyo a discapacitados. . . . . 134

B.6. Matriz de transición de la etapa  $t + 1$  . . . . . 135

# Índice de tablas

4.1. Clasificador bayesiano usado para determinar la clase piel en diferentes espacios de color. . . . .	41
4.2. Porcentaje de reconocimiento promedio correspondiente a 7 gestos . . . . .	66
4.3. Matriz de confusión mostrando porcentajes de reconocimiento sin usar contexto . . .	68
4.4. Matriz de confusión mostrando porcentajes de reconocimiento al usar contexto . . .	68
4.5. Matriz de confusión mostrando los porcentajes de reconocimiento . . . . .	68
6.1. Promedio de los tiempos de respuesta del modelo . . . . .	88
6.2. Puntaje obtenido por el operador humano . . . . .	98
6.3. Puntaje obtenido al evaluar el modelo un grupo de 10 participantes. . . . .	98
6.4. Evaluación del escenario de video conferencia. . . . .	99
6.5. Puntaje obtenido al evaluar las decisiones seleccionadas por un asistente humano. . .	101
6.6. Puntaje obtenido al evaluar el modelo un grupo de 5 participantes. . . . .	101
6.7. Evaluación del escenario de apoyo a discapacitados. . . . .	102
A.1. Subconjuntos de características utilizados . . . . .	120

# Capítulo 1

## Introducción

Dentro del amplio rango de actividades humanas, los gestos realizados con las manos ocupan un lugar importante en la vida cotidiana. Así que el diseño de sistemas automáticos que reconozcan de manera confiable tales gestos es un área de investigación relevante. Sin embargo, es aún más interesante saber *qué hacer con los gestos reconocidos*, ya que permite incorporar en los sistemas automáticos aspectos como la toma de decisiones. Por lo tanto, consideramos que los sistemas automáticos que tomen decisiones dinámicas basados en información visual del comportamiento humano, ofrecen una amplia gama de aplicaciones, y son a la vez, un área de investigación relativamente nueva con buenas oportunidades de investigación. En esta tesis, se propone un nuevo enfoque para tomar decisiones dinámicas basándose en los gestos realizados por una persona al manipular objetos en escenarios conocidos.

### 1.1. Tipos de gestos

Mientras el uso de gestos para fines de comunicación es un aspecto importante, muchos de los gestos realizados por humanos producen cambios físicos en el ambiente. Por ejemplo, *tomar una hoja de papel para escribir sobre ella, tomar una toalla para secarse las manos*. Aunque el objetivo primario de tal gesto es la interacción con un objeto del ambiente, otras personas o sistemas inteligentes pueden observar el gesto y razonar al respecto con la intención de reconocer el gesto y su utilidad. Este razonamiento, puede tener varios propósitos. Por ejemplo, en un ambiente de videoconferencias es conveniente que el sistema inteligente seleccione la mejor vista que se debe mostrar a la audiencia como resultado de observar los gestos realizados por el expositor. Asimismo, en un escenario de apoyo a discapacitados el mismo sistema debe seleccionar con base en el comportamiento de una persona, la mejor acción (a través de una instrucción audible) para ayudarla a completar una tarea.

De acuerdo con Bobick [10], los gestos pueden ser divididos en dos amplias categorías: *gestos comunicativos* y *gestos manipulativos*. La distinción entre ellos es la siguiente:

a) *Gestos comunicativos*. Son los utilizados por humanos en la vida cotidiana para propósitos de comunicación. La intención es que sean comprendidos por otras personas observando solamente los movimientos o posturas de la mano del gesticulador.

b) *Gestos manipulativos*. Son diferentes en naturaleza ya que su objetivo primario es la manipulación de objetos. Una característica importante de estos gestos es que producen cambios en el escenario. Por ejemplo, para escribir sobre una hoja de papel, normalmente se tiene que *tomar la hoja de papel, moverla de posición, se escribe sobre ella* y después *se deja donde estaba o se coloca en otra posición*. Lo mismo sucede al *tomar un jabón para enjabonarse las manos* o cuando *se hojea un libro*.

La mayoría de los trabajos publicados para automatizar el reconocimiento de gestos, se refieren al reconocimiento de *gestos comunicativos* [58, 86, 119], los cuales son utilizados principalmente para la instrucción de sistemas [9, 110, 116]. En contraste, el reconocimiento de *gestos manipulativos* es un tópico relativamente inexplorado. Algunos enfoques intentan el reconocimiento de gestos basados solamente en información contextual (*simbólica*) extraída de la escena [66, 72, 104]. Otros enfoques hacia el reconocimiento de gestos manipulativos, trabajan directamente con datos de la imagen y se basan en la trayectoria de la mano para enfocar áreas de la imagen relevantes y de esta manera reconocer alguna acción [5, 89].

Las acciones reconocidas son definidas en términos de características de bajo nivel de la imagen, por ejemplo, en el trabajo propuesto por Shah y otros [5] un cambio de intensidad en regiones previamente definidas en un escenario indica la realización de una actividad (abriendo un cajón, por ejemplo). De esta forma, la información contextual indicando un cambio en el estado de un objeto (cajón abierto), es la única característica usada para el reconocimiento. En el análisis de características de bajo nivel de la imagen, la cercanía de la mano a un área predefinida es utilizada para hipotetizar acciones. Obviamente, en este caso no existe un análisis sofisticado de los datos ya que el único propósito al analizar la trayectoria es seleccionar áreas de la imagen que sean de interés para extraer información contextual. Un notable enfoque al reconocimiento de acciones que combina información sensorial y contextual, es el trabajo realizado por Darnell y otros [76]. En su trabajo, la información contextual de los objetos en la vecindad de la mano se realiza después de analizar los datos correspondientes al movimiento de la misma. En un enfoque similar al de Darnell, Fritsch [31] propone un trabajo para reconocer gestos manipulativos que se caracterizan principalmente por su interacción con el ambiente, pero que no tienen una trayectoria característica (manipulación de objetos con fines de ensamble), escenario típico de construcción y ambiente de oficina. En su enfoque, integra información relacionada con objetos del entorno, así como información relacionada a los movimientos de las manos de una persona al interactuar con tales objetos.

Debido al amplio uso que tienen los gestos comunicativos en varias aplicaciones, la detección y seguimiento de manos en una secuencia de imágenes es un campo de investigación de gran interés [92, 106, 123]. En la observación de movimientos de las manos, se han utilizado diferentes tipos de sensores. Básicamente, los movimientos de la mano pueden medirse, ya sea, a través de sensores atados directamente a las manos, o a través de algún mecanismo de medición remoto. Mientras el uso de sensores atados a la persona es fácil de realizar desde un punto de vista técnico, requiere que la persona use algún dispositivo especial (métodos intrusivos), esto ocasiona en algunos casos que la manipulación de objetos se vuelva complicada o tal vez, imposible. Asimismo, este requerimiento se contrapone al objetivo de diseñar sistemas que sean amigables con el usuario y fáciles de usar. Por otro lado, las técnicas de medición remotas son más atractivas ya que permiten a cualquier usuario interactuar inmediatamente con el sistema y sin alguna preparación. Desde la perspectiva de un diseñador de sistemas resulta atractivo el uso de técnicas de medición remotas ya que permiten a una persona el manejo de objetos de forma natural y sin restricciones de algún tipo.

El reconocimiento de gestos manipulativos requiere el análisis conjunto de información con-

textual y movimiento de la mano, con el fin de eliminar la ambigüedad existente en trayectorias similares y al mismo tiempo reconocer un mayor número de gestos. La información contextual es esencial en el reconocimiento de gestos manipulativos. Generalmente, esta información se integra por datos de objetos extraídos del escenario con los cuales la persona interactúa [31, 76, 108], aunque en algunos casos se forma por relaciones entre partes del cuerpo humano [98]. Detectar y reconocer a los objetos que interactúan con una persona en un escenario no es trivial. Actividades de investigación recientes relacionadas con el reconocimiento de objetos indican que es una tarea desafiante [3, 55, 90, 115]. Los movimientos de traslación y rotación no cambian al objeto en sí, pero su apariencia puede variar debido a nuevos ángulos de vista o diferentes condiciones de iluminación. El reconocimiento de objetos rígidos, bajo diferentes ángulos de vista y condiciones de iluminación, ya es por sí misma una tarea desafiante para los algoritmos de reconocimiento de objetos [3, 107, 115]. El reconocimiento de objetos se vuelve un problema abierto, si se trata de objetos flexibles, que adquieran variadas formas y cambian de manera impredecible. Por lo tanto, la mayoría de las veces, es necesario aplicar algunas restricciones durante el proceso de detectar y localizar objetos dentro de un escenario complejo.

Los trabajos de reconocimiento de gestos mencionados con anterioridad tienen algo en común: realizan el proceso de reconocimiento a un nivel de clasificación; es decir, realizan el reconocimiento para indicar la pertenencia de un gesto dentro de un grupo previamente definido. Sin embargo, existen trabajos relacionados con el reconocimiento de gestos que involucran aspectos de teoría de decisiones con fin de mejorar el proceso [6, 24, 41]. Introducir aspectos de tomar decisiones permite extender el proceso para buscar la utilidad de un gesto. Esto es, una vez que se reconoce un gesto, se decide en un paso posterior, qué acción tomar, lo cuál es más atractivo que la simple clasificación. Esta integración permite el desarrollo de sistemas autónomos capaces de tomar decisiones en ambientes complejos, basándose en información proporcionada por técnicas de visión computacional.

## 1.2. Teoría de decisiones

Actualmente existen pocos trabajos publicados que integran aspectos de visión computacional y teoría de decisiones. Los que emplean este enfoque, lo hacen con el fin de reconocer gestos u objetos, a través de controlar cámaras activas [24]. O bien, intentan el enfoque desde la perspectiva de agentes, con el fin de aprender la utilidad de algunos gestos o manejo de diálogos [60, 78].

Darrell y otros [24], desarrollan un sistema para reconocer activamente los gestos realizados por una persona. Es un esquema de atención visual, donde una cámara activa recibe comandos para obtener información relacionada a enfocar partes de una imagen relevantes al proceso de reconocimiento. Su enfoque lo basan en un proceso de decisión de Markov parcialmente observable (POMDP). Un trabajo parecido es realizado por Bandera y otros [6] donde a través de un enfoque de aprendizaje por refuerzo intentan mejorar un mecanismo de atención visual. La intención es simular un sistema basado en visión para aprender estrategias empleando información visual relevante a la tarea. Por su parte Hoey y otros [41] proponen un modelo adaptativo basado en visión y teoría de decisiones con el fin de aprender expresiones faciales. Consideran que el reconocimiento de un gesto facial se obtiene al observar relaciones entre acciones, respuestas y utilidades. Mantienen que su sistema puede aplicarse en cualquier situación donde no se requieran expresiones verbales para realizar una tarea, a pesar de que una expresión facial guarda una fuerte correlación con una expresión verbal. En un trabajo similar al de Hoey Morency y otros [60, 78] investigan cómo el contexto de diálogos puede mejorar el reconocimiento visual de gestos de usuarios.

Es notable con base en trabajos de investigación recientes [11,41–43,60], el interés que existe en desarrollar sistemas computacionales que extiendan el proceso de clasificación de gestos un paso adelante. La finalidad, es incluir mecanismos que permitan conocer la utilidad de los gestos, para ello es necesario involucrar aspectos de teoría de decisiones. Conocer la utilidad de los gestos, es sin duda relevante para una gran variedad de tareas. Por ejemplo, un sistema inteligente que decida qué información enviar a la audiencia cuando observa una videoconferencia. Un sistema que instruya a una persona discapacitada para que complete una tarea a través de mensajes audibles. Un sistema de seguridad que reconozca el comportamiento de una persona, seleccione y envíe información que considera relevante. Estos son algunos de los ejemplos que se pueden citar. Por lo tanto, es una gran motivación participar en el desarrollo de estos sistemas.

### 1.3. Objetivo de la tesis

*Esta tesis tiene como finalidad el diseño de un nuevo modelo computacional que permite el reconocimiento automático de gestos utilizando información de contexto, integrado en un esquema de toma de decisiones con el fin de seleccionar acciones óptimas<sup>1</sup>.*

### 1.4. Metas

1. Realizar el reconocimiento visual de gestos utilizando un enfoque basado en el análisis de movimiento y contexto.
2. Desarrollar un modelo de toma de decisiones basado en el análisis de un número finito de etapas temporales.
3. Apoyar actividades realizadas en aplicaciones novedosas tales como: videoconferencias y apoyo a discapacitados.

### 1.5. Alcances

Para el desarrollo de este nuevo modelo computacional se van a tomar en cuenta las siguientes consideraciones:

1. Las decisiones tomadas por el sistema van a ser basadas en el comportamiento de una persona al realizar gestos manipulativos con objetos presentes en un escenario específico.
2. Solamente se considera el reconocimiento de gestos manipulativos de acuerdo con la definición de Bobick [10]. Asimismo, se puede utilizar de manera intercambiable la notación gesto o comportamiento humano, para indicar los movimientos realizados por una persona al manipular objetos de un escenario.

---

<sup>1</sup>La acción es óptima de acuerdo con los objetivos del modelo y se obtiene aplicando el enfoque de máxima utilidad esperada [99,101]

3. Se va a definir contexto o información contextual: la información relacionada con los objetos de interés presentes en un escenario específico, observados por una cámara estática y los cuales son manipulados por una persona.
4. La obtención de información tanto de movimiento como contextual, se obtiene aplicando métodos no intrusivos (cámaras de vídeo).
5. Los objetos con los cuales interactúa una persona se consideran rígidos, es decir, no cambian de manera significativa su forma o apariencia al ser manipulados.
6. La perspectiva utilizada en el reconocimiento de gestos es la siguiente: (i) los movimientos permitidos durante la manipulación de objetos son de rotación y/o traslación y (ii) un objeto no cambia sustancialmente su apariencia visual al ser observado por una cámara de vídeo durante su manipulación.

## 1.6. Metodología

Se presenta el diseño de un modelo computacional que reconoce el comportamiento humano utilizando contexto y toma decisiones basado en esta información. El modelo desarrollado permite el reconocimiento de actividades humanas realizadas en escenarios conocidos. El reconocimiento de actividades o gestos se determina al interactuar una persona con objetos del entorno. A su vez la toma de decisiones dinámicas se realiza al analizar una serie de etapas temporales y se basa en seleccionar la acción con la máxima utilidad esperada. Para realizar lo anterior, se aplica en este trabajo un enfoque modular *ascendente* tal como se muestra en la Figura 1.1. Una breve explicación de la estructura del modelo se ofrece a continuación.

### 1.6.1. Descripción de componentes

El modelo se estructura en cuatro módulos los cuales por su función se integran en dos y se muestran encerrados por líneas punteadas en la Figura 1.1: (a) módulo de reconocimiento de gestos (**I**), el cual combina información de movimiento y de contexto bajo un nuevo enfoque y, (b) módulo para la toma de decisiones (**II**), el cual permite tomar decisiones en problemas POMDPs de horizonte finito. La descripción de cada componente de los módulos se presenta a continuación.

**Procesamiento de imágenes y extracción de características.** Este módulo se encarga de procesar la información visual a partir de una secuencia de imágenes. La información corresponde a gestos realizados por una persona al manipular objetos del entorno, los cuales son capturados por una cámara de vídeo. Durante esta etapa se aplican técnicas de visión para realizar un procesamiento previo a cada imagen y determinar tanto la segmentación de regiones de piel en movimiento como la ubicación de los objetos en el escenario. Los algoritmos aplicados en este paso son técnicas utilizadas para el proceso de filtrado, representación basada en histogramas, método de sustracción de imágenes y un proceso de clasificación utilizando la regla de Bayes. Asimismo, se utiliza un nuevo modelo de color para reconocer piel basado en las componentes *RGY*. Posteriormente, se realiza el seguimiento tanto de la mano de la persona que manipula un objeto conocido como del objeto en cuestión, para esto se aplica una modificación del algoritmo *CamShift* [16]. Durante el seguimiento se extraen las características que se van a utilizar para representar a cada gesto. Estas características se basan en

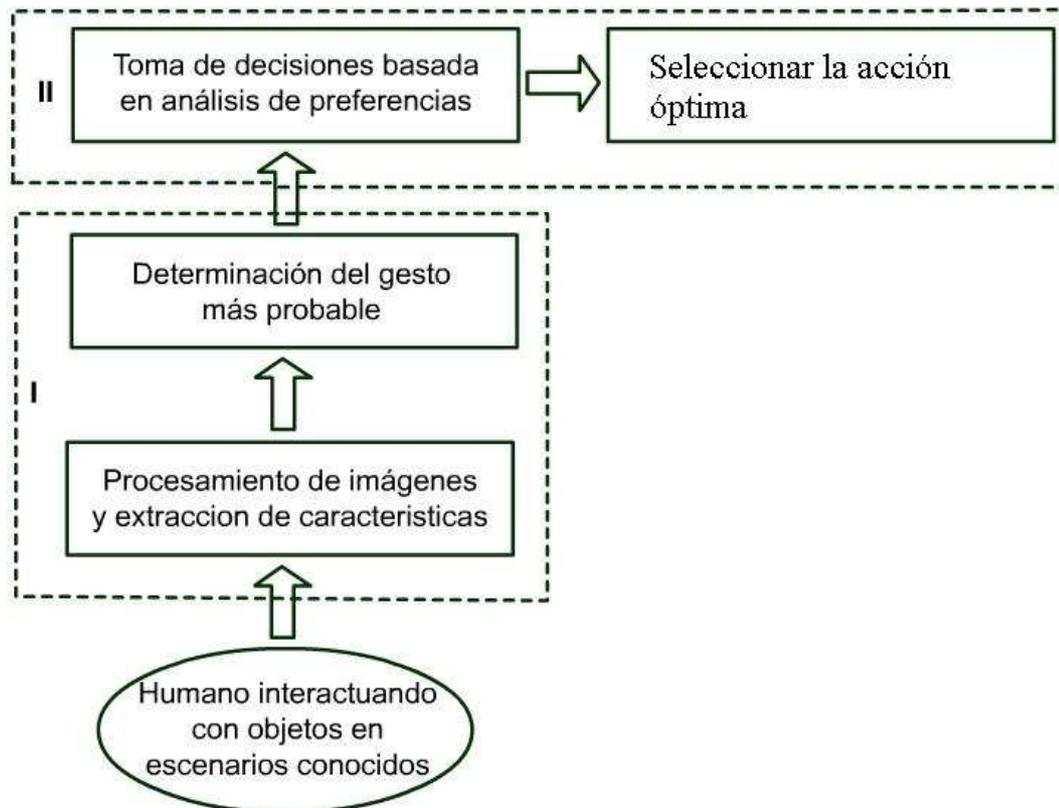


Figura 1.1: Diagrama de bloques del modelo desarrollado.

la trayectoria descrita por el centroide de la mano y son extraídas y analizadas mediante un proceso exhaustivo [113] con el fin de obtener el conjunto mínimo de ellas que representa a cada gesto.

**Determinación del gesto más probable.** Para reconocer el gesto más probable que realiza una persona en un escenario conocido, se utiliza la integración de características de movimiento (trayectoria del centroide de la mano) y contexto (objetos) bajo un enfoque estadístico [73]. La técnica aplicada se basa en los modelos ocultos de Markov [95], la cual permite la representación y análisis de datos secuenciales en el tiempo, tal como los gestos realizados por una persona al interactuar con objetos del entorno. La integración de esta información se realiza durante la fase de entrenamiento de estos modelos. Previo al proceso de aprendizaje, los datos utilizados son discretizados aplicando el algoritmo *k-means* [38].

**Toma de decisiones.** Este módulo permite tomar decisiones basadas en el gesto observado más probable. Se incorpora un nuevo esquema para tomar decisiones dinámicas en escenarios reales utilizando redes de decisión dinámicas [74, 75]. Este enfoque resuelve problemas de decisión de Markov parcialmente observables con horizonte finito. El uso de redes de decisión dinámicas para resolver este tipo de problemas, enfrenta el desafío de determinar el número de etapas temporales necesarias para tomar una decisión. Este problema se resuelve al establecer un compromiso entre el comportamiento de las utilidades máximas a través de diferentes etapas temporales en avance y el tiempo de respuesta que debe ser proporcionado por el sistema en escenarios reales. La evaluación de las redes de decisión dinámicas se realiza aplicando técnicas clásicas de inferencia estadística utilizadas en redes bayesianas [46].

**Seleccionar la mejor acción.** El enfoque que se utiliza para seleccionar la mejor acción se basa en la máxima utilidad esperada [101]. Éste es un enfoque basado en preferencias hacia los gestos observados y acciones probables. En este trabajo, se utilizan para determinar la acción más probable las tablas de utilidad, matrices de transición y gestos probables.

### 1.6.2. Resultados obtenidos

Los resultados obtenidos en este trabajo se presentan en dos partes y son las siguientes:

1. **Reconocimiento de gestos utilizando contexto.** Para conocer el efecto del uso de contexto en el proceso de reconocimiento de gestos se utilizan dos escenarios: i) gestos que se realizan en un ambiente de oficina: usar la computadora, contestar el teléfono, escribir/borrar en una hoja, hojear un libro, tomar una taza y ii) gestos que se realizan en un lavabo: abrir/cerrar el grifo, usar el jabón, lavarse las manos, enjabonarse, secarse las manos. En el primer escenario, se tomaron 100 muestras de cada gesto y utilizando solamente las características de movimiento, se emplearon 70 muestras para entrenar a los modelos ocultos de Markov y 30 muestras para la evaluación. Resultados experimentales muestran un porcentaje de reconocimiento promedio para los gestos en el intervalo 52 % – 97 % [113]. Al incorporar la información de contexto (objetos) en el mismo escenario, el rango de reconocimiento de gestos promedio se incrementa y se ubica en el intervalo 87 % – 99.57 % [73]. En el segundo escenario se realizó el proceso de reconocimiento integrando información de movimiento y contexto. Se consideraron 50 muestras de cada gesto realizadas por una persona, de las cuales se utilizaron 35 muestras para el entrenamiento y 15 para el proceso de evaluación. Los resultados experimentales muestran un reconocimiento promedio para los gestos considerados de 94 % [73].
2. **Evaluación del modelo para seleccionar acciones.** Para evaluar el aspecto de la toma de decisiones basada en el comportamiento del usuario, se realizan dos tipos de pruebas: (i) En la primera se verifica la eficiencia del modelo basados en criterios de: tiempo de respuesta y selección de acciones óptimas, y (ii) En la segunda prueba se busca determinar la utilidad del modelo al ser comparado contra un humano en escenarios *reales*. Para obtener esta información el modelo fué implementado en dos distintos escenarios: Videoconferencias y Apoyo a personas discapacitadas [74,75]. Una breve descripción de cada prueba se muestra a continuación.
  - a) **Evaluación experimental para medir la eficiencia del modelo, sujeta a criterios de tiempo de respuesta y selección de la acción óptima.** El tiempo de respuesta proporcionado por el modelo se obtuvo al analizar la red de decisión dinámica (que representa a cada escenario), variando el número de etapas temporales bajo diferentes algoritmos de inferencia. Se evaluaron 3 algoritmos de inferencia (1 exacto, 2 aproximados) utilizados en redes bayesianas, los resultados indican que es posible obtener un tiempo de respuesta satisfactorio<sup>2</sup> en este tipo de aplicaciones al analizar entre 4 y 7 etapas temporales en avance, asimismo, los resultados sugieren que es suficiente el uso del algoritmo exacto propuesto por Huang y Darwiche [46] para realizar la inferencia. Para evaluar la eficiencia del modelo para seleccionar acciones óptimas se analizó una red de decisión dinámica

---

<sup>2</sup>Se va a considerar un tiempo satisfactorio en este trabajo, al rango de tiempo considerado entre 1 y 7 segundos basados en los trabajos de Tsykin [111] y Murray [80].

(representativa para cada escenario), al variar sus condiciones de operación (objetivos del sistema y creencias hacia los estados). Los resultados obtenidos muestran que el modelo propuesto es confiable ante ligeros cambios de las condiciones de operación.

- b) **Comparación de la toma de decisiones realizada por el modelo contra la toma de decisiones realizada por un humano.** En esta evaluación se compara la eficiencia del modelo propuesto para seleccionar acciones contra las acciones seleccionadas por un humano en los mismos escenarios. Los resultados obtenidos en esta prueba se basaron en una encuesta realizada a un grupo de participantes. Los criterios de evaluación utilizados en este caso fueron: **sensibilidad, estabilidad y congruencia** los cuales fueron considerados en un escenario de videoconferencia, y **grado de especificación de los mensajes, efectivo y oportuno** para un escenario de apoyo a personas con problemas de memoria y/o discapacitados<sup>3</sup>. Los resultados obtenidos aplicando la escala de Likert [109] al evaluar los aspectos anteriores, indican una opinión favorable en la toma de decisiones realizada por el sistema propuesto en los escenarios utilizados.

Por lo tanto, consideramos que el sistema diseñado es capaz de tomar decisiones dinámicas en ambientes reales basado en el comportamiento humano, utilizando para este fin un modelo confiable para el reconocimiento contextual de gestos.

## 1.7. Contribuciones

Las principales contribuciones de la tesis son:

- Se muestra el uso de un nuevo modelo de color basado en los componentes RGY que resulta muy eficiente para reconocer regiones de piel en una secuencia de imágenes. Este método se incorpora en la etapa de detección y seguimiento de las partes de una persona en ambientes reales integrando el color de piel y movimiento.
- Se muestra un procedimiento exhaustivo para la extracción de las características utilizadas aplicando como criterio de selección el rendimiento de los modelos ocultos de Markov. Mediante este proceso de selección, discretización y evaluación se seleccionan las *mejores* características para reconocer un conjunto de gestos. Este esquema resulta adecuado para extraer el menor conjunto de características que representan diversos gestos.
- Se incorpora una variación al algoritmo CamShift que permite un ajuste máximo en la ventana de seguimiento, el cual resulta apropiado para seguir partes de objetos.
- Se propone un esquema para incorporar información de contexto en los modelos ocultos de Markov, lo cual permite mejorar el proceso de reconocimiento de gestos manipulativos.
- Se propone un nuevo esquema para la toma de decisiones dinámicas en ambientes reales aplicando redes de decisión dinámicas (RDDs). El modelo presentado permite utilizar información visual del comportamiento humano como base para la toma de decisiones dinámicas aproximando la solución de un POMDP con un horizonte finito. Este esquema permite tomar decisiones en tiempos finitos lo cual resulta adecuado para una variedad de aplicaciones.

---

<sup>3</sup>Este fué un escenario simulado, ya que las personas participantes no son discapacitadas y tampoco tienen problemas de memoria.

- Se incorpora el uso de escenarios novedosos tal como el ambiente de videoconferencias y apoyo a personas para completar tareas, en sistemas que toman decisiones basados en el reconocimiento contextual de gestos.

## 1.8. Organización de la tesis

Una breve descripción del contenido de la tesis se presenta a continuación.

En el Capítulo 2 se muestran algunos de los trabajos que se han desarrollado para reconocer de manera automática los gestos realizados por una persona al realizar tareas cotidianas. Estos trabajos se van a presentar tomando como referencia el empleo de información contextual. En el Capítulo 3, se describen algunas técnicas traídas de la comunidad de Investigación de Operaciones (IO), para enfrentar el problema de tomar acciones óptimas en dominios estocásticos parcialmente observables. En el Capítulo 4, se describen las fases empleadas durante el proceso de reconocimiento de gestos al interactuar las manos de una persona con objetos del entorno (información de contexto). En el Capítulo 5, se describe el proceso para integrar la información visual y la toma de decisiones a través de las redes de decisión dinámicas (RDDs), asimismo, se proporciona una descripción de los escenarios utilizados. El Capítulo 6 describe las pruebas experimentales realizadas para evaluar el modelo desarrollado en dos escenarios: videoconferencias y apoyo a personas con problemas de memoria. Finalmente en el Capítulo 7, se mencionan las conclusiones, aportaciones y trabajo futuro.

# Capítulo 2

## Reconocimiento de gestos humanos

En este capítulo se presentan algunos de los trabajos que se han desarrollado para reconocer de manera automática los gestos realizados por una persona al hacer tareas cotidianas. Estos trabajos se van a presentar tomando como referencia el empleo de información contextual. Este enfoque se describe en la Sección 2.1, donde se presenta la introducción del capítulo. En la Sección 2.2, se describen algunos trabajos representativos que reconocen gestos sin utilizar información contextual. En la Sección 2.3, se muestran trabajos que realizan el reconocimiento de gestos basados principalmente en información de contexto. Los trabajos que combinan la información de contexto con información relacionada al análisis del movimiento para reconocer actividades humanas se describen en la Sección 2.4. La extensión al proceso de reconocimiento de la actividad humana con el fin de tomar decisiones, o la utilidad de los gestos, se describe en la Sección 2.5. Finalmente en la Sección 2.6, se presenta un resumen de capítulo resaltando aspectos relevantes del mismo.

### 2.1. Introducción

El desarrollo de sistemas automáticos o *semi – automáticos* con el fin de reconocer actividades humanas, es un área de gran interés debido a múltiples aplicaciones [1, 10]. Al realizar una revisión de la mayoría de los trabajos publicados que reconocen la actividad humana, se determinan dos tendencias: a) los trabajos que utilizan de forma explícita información del escenario donde se encuentra la persona o personas, con el fin de apoyar el reconocimiento de actividades humanas, y b) los trabajos que asumen de manera implícita dicha información y basan el reconocimiento en el análisis del movimiento. La mayoría de los trabajos realizados [2, 25, 44, 56, 64, 84, 85, 103, 106, 117, 122] para reconocer la actividad humana se clasifican dentro del segundo grupo. Estos métodos confían en técnicas de análisis de movimiento con el fin de modelar la actividad humana y, generalmente se limitan al reconocimiento de gestos simples (*caminar, saltar, saludar, caer*). Sin embargo, estos métodos no son capaces de describir actividades complejas tales como las realizadas en un ambiente de videoconferencias o de oficina (*escribir/borrar en una hoja de papel, estar usando la computadora, mostrar una figura en un libro, contestar el teléfono, abrir/cerrar un cajón*), es decir, gestos donde se involucra la manipulación de objetos del escenario. Ya se ha demostrado en trabajos previos [31, 76, 108], que el uso de información relacionada al escenario en cuestión o información contextual (como será definida en adelante), es fundamental para reconocer el comportamiento humano complejo (*ambientes reales e interactuando con objetos*). Sin embargo, han sido pocos los intentos realizados hasta el momento con el fin de incorporar dicha información al proceso de reconocimiento automático de gestos y

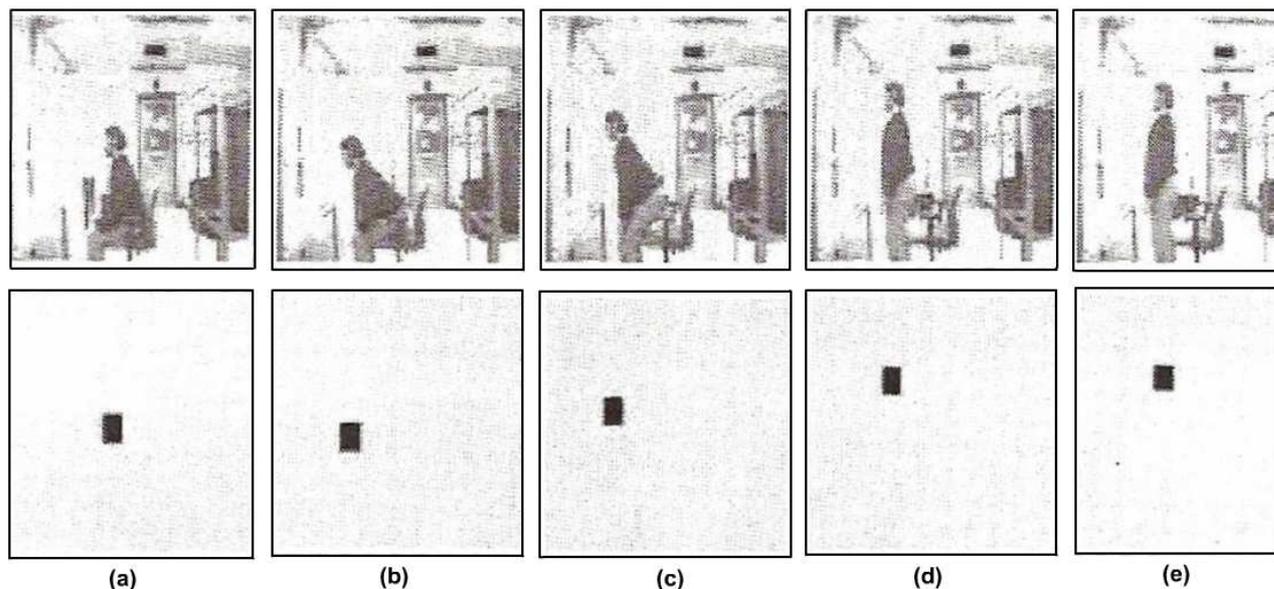


Figura 2.1: La secuencia de imágenes (a-e) mostrada ilustran a una persona parándose de una silla. En la parte superior se observan las imágenes capturadas en distintos instantes de tiempo. Las imágenes de abajo muestran la trayectoria descrita por el centroide de la cabeza correspondiente a las imágenes mostradas arriba [64].

más escasos aún, los trabajos que extienden este proceso con el fin de tomar decisiones racionales en ambientes reales.

Con el fin de simplificar el proceso de reconocer gestos o actividades humanas realizadas en diferentes escenarios, y donde se observa la interacción con objetos del entorno, este trabajo se apoya en la siguiente observación: las actividades o gestos realizadas por una persona se restringen de forma natural al ambiente. Por ejemplo, resulta natural que una persona esté realizando ejercicios en un parque o en un gimnasio, pero no es común observar esta actividad en una oficina o sala de conferencias. Por lo tanto, conocer el escenario donde se encuentra la persona y los objetos con los que interactúa apoya el proceso de reconocer actividades humanas.

Enseguida se presentan algunos trabajos representativos que realizan el reconocimiento automático de la actividad humana sin utilizar información de contexto.

## 2.2. Reconocimiento de gestos sin aplicar contexto

Los trabajos enfocados al reconocimiento automático de la actividad humana que no utilizan información de contexto, normalmente se basan en el análisis del movimiento de una o más partes del cuerpo humano (obtenido a través de información visual proporcionada por una o más cámaras de vídeo), con el fin de realizar la interpretación del gesto. Madabhushi y Aggarwal [64], proponen un enfoque Bayesiano en el cual analizan la trayectoria descrita por la cabeza de una persona al realizar diferentes actividades (ver Figura 2.1). A pesar de que el método propuesto es simple y con la posibilidad de ser aplicado en tiempo real, presenta algunas limitaciones. Al depender solamente del análisis descrito por la trayectoria de la cabeza, no es capaz de discriminar actividades similares tales como *agacharse* y *sentarse*. Asimismo, las actividades se limitan a las realizadas por una persona al desplazarse por su entorno: *caminar*, *saltar*, *sentarse*, las cuales para muchas aplicaciones no son

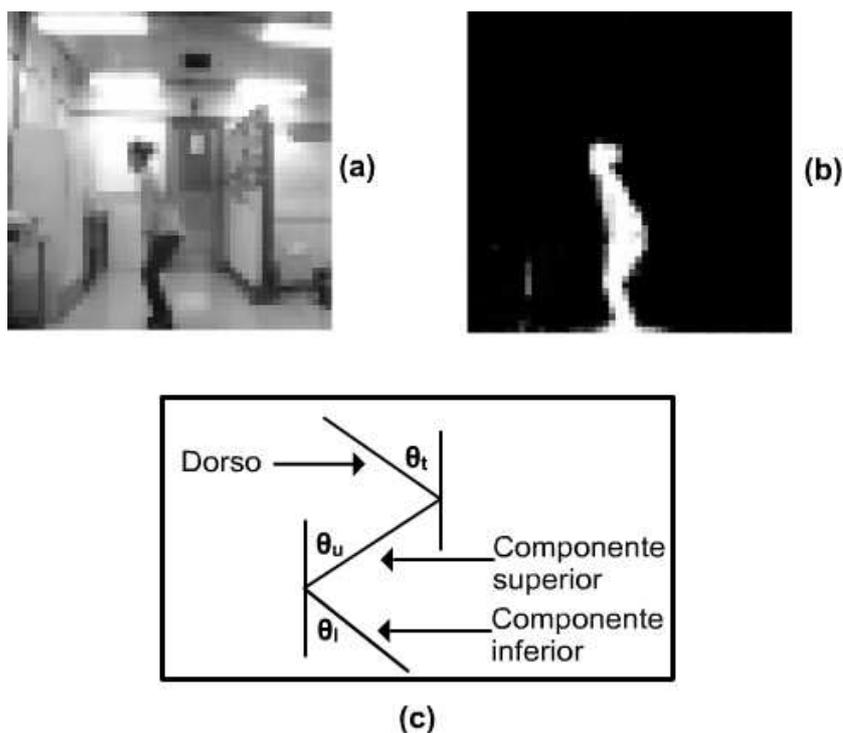


Figura 2.2: Enfoque utilizado por Ali para reconocer gestos, (a) Imagen original mostrando a una persona parándose, (b) Imagen segmentada de la persona mostrada en (a), (c) representación esquemática de los componentes del cuerpo y ángulos asociados [2].

de gran utilidad. Otra limitante que presenta este método es que la segmentación de la cabeza se realiza de manera manual, a diferencia de la mayoría de los trabajos que hacen este proceso de forma automática. Al no emplear información adicional, tal como el conocimiento del entorno, este método necesita un gran número de datos de entrenamiento con el fin de obtener un grado de confiabilidad aceptable en el proceso de reconocimiento.

El análisis de los ángulos que forman algunas partes del cuerpo al realizar ciertos movimientos, ha sido utilizado para diseñar sistemas que reconozcan de manera automática actividades humanas. Bajo este enfoque, el trabajo desarrollado por Ali y otros [2], está basado en el análisis de los ángulos que forman tres componentes del cuerpo: (i) el dorso, (ii) el componente superior de la pierna y (iii) el componente inferior de la pierna, con el eje vertical del cuerpo (ver Figura 2.2). Para que las actividades puedan ser reconocidas la persona no debe presentar oclusión en estas partes, y ofrecer una vista lateral a la cámara libre de obstáculos. Los autores sostienen que analizando estos ángulos se obtiene un reconocimiento continuo de actividades sin necesidad de incluir pausas para determinar entre una actividad y otra. El vector que caracteriza a cada actividad está representado por los ángulos mencionados, los cuales son determinados de manera experimental. El reconocimiento de una actividad se realiza aplicando la distancia euclidiana entre el vector de entrada y vectores previamente almacenados. El vector con la menor distancia determina la actividad reconocida. Sin embargo, al igual que el trabajo de Madabhushi [64], el método propuesto por Ali y otros, solamente reconoce acciones caracterizadas por el desplazamiento de una persona en un entorno libre de obstáculos, tales como: *sentarse*, *pararse*, *caminar*. Un trabajo similar al de Ali es desarrollado por Yazer y otros [103], donde reconocen gestos en una base *espacio – tiempo* tomando como característica representativa de los gestos los ángulos extraídos por un sistema de observación visual. Mencionan que, utilizando suficiente información, una acción puede ser reconocida a través de comparar el ángulo en el subespacio de los ejemplos y el ángulo obtenido en el subespacio de la instancia a inspeccionar. Sin

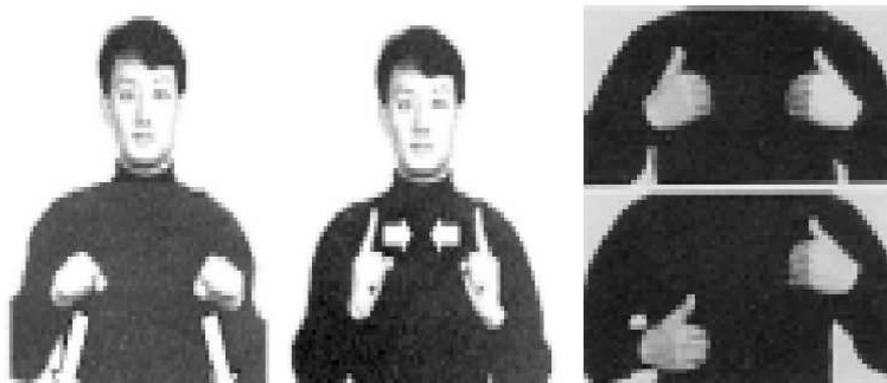


Figura 2.3: Imágenes utilizadas por Kim y otros durante el reconocimiento de gestos para el lenguaje de señas. La secuencia mostrada representa la frase: *Hola, gusto en conocerte* [56].

embargo, estos métodos no son capaces de reconocer actividades complejas tales como las realizadas por personas al interactuar con objetos del entorno. Asimismo, tampoco son capaces de manejar la oclusión, la cual es muy común en las actividades realizadas en el mundo real.

El reconocimiento de gestos realizados por las manos bajo un enfoque lingüístico, ha sido de gran utilidad en aplicaciones de comunicación con base en señas. Uno de estos trabajos es el realizado por Kim y otros [56], en el cual se reconoce un total de 18 gestos realizados por las manos y las combinaciones de estos gestos son utilizadas para representar palabras del vocabulario coreano (ver Figura 2.3). Los autores se basan en una combinación de particionamiento difuso y autómatas de estados para modelar los patrones de movimientos realizados por las manos al realizar gestos comunicativos. Por el momento reportan el reconocimiento de 18 oraciones con una confiabilidad del 94 %. En este tipo de aplicaciones, se considera que, tanto la velocidad ( $s_i = \sqrt{(x_i - x_{i-1})^2 + (y_i - y_{i-1})^2}$ ) en los movimientos de la mano (trayectoria de la mano), como los cambios de velocidad ( $cs_i = s_i - s_{i-1}$ ), son aspectos relevantes para el sistema de reconocimiento.

Aunque este trabajo en particular no utiliza guantes de color para identificar las manos, la mayoría de trabajos realizados en este tipo de aplicaciones los usan [44, 85, 106]. El reconocimiento de gestos en trabajos relacionados con lenguajes de señas, generalmente simplifican la etapa de tratamiento de imágenes al manejar colores para distinguir las manos. El proceso de reconocimiento se basa exclusivamente en un enfoque lingüístico (mapeo de señales a símbolos gramaticales), por lo que estos trabajos se orientan a un reducido grupo de aplicaciones. En particular, los trabajos desarrollados por Kim [56] y Hong [44], aplican autómatas, esto permite una interpretación de alto nivel, sin embargo, no permite el manejo de incertidumbre, característica de la mayoría de los ambientes reales.

El uso de histogramas para modelar imágenes con historias de movimientos son empleados por Davis [25]. Los movimientos que realiza una persona al sentarse o pararse (ver Figura 2.4) son caracterizados por múltiples histogramas, representando orientaciones locales de cada movimiento. Davis, llama a la caracterización de un gesto, observado a través de diferentes vistas y por un tiempo determinado *plantillas temporales*, las cuales son representaciones basadas en múltiples histogramas. El reconocimiento de un movimiento, se realiza comparando el histograma que representa a un gesto de entrada, con histogramas previamente almacenados (modelos de gestos). Se busca en este proceso una correspondencia entre histogramas. La correspondencia se determina, al comparar siete momentos caracterizando a cada movimiento almacenado con el movimiento de entrada. Otro trabajo que emplea histogramas para reconocer gestos es el desarrollado por Freeman y otros [29]. En

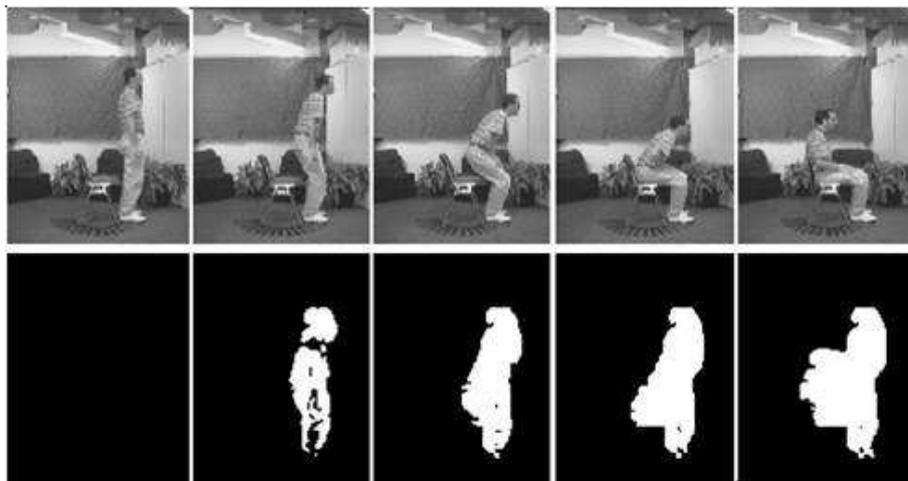


Figura 2.4: Secuencia de imágenes utilizadas por Davis donde se muestra la historia de movimiento acumulado de una persona al realizar la acción de sentarse [25].

este enfoque, los histogramas representan diferentes orientaciones de la mano al realizar un gesto. El reconocimiento de un gesto se realiza concatenando histogramas de orientación individuales. Su aplicación es hacia el reconocimiento de gestos estáticos.

Aunque la representación de los movimientos basada en histogramas es simple y con posibilidad de aplicarse en tiempo real, esta técnica representa características globales de una imagen. Esto es, indica que algún tipo de movimiento sucede en la imagen pero no especifica dónde, ni mucho menos si se está interactuando con algún objeto del entorno. Estos trabajos son aplicables para reconocer actividades simples, sin oclusiones y generalmente bajo condiciones controladas. Asimismo, el uso de plantillas estáticas para representar estructuras temporales puede ser sensible al ruido, y a ambigüedades. Estas limitaciones pueden ser manejadas usando técnicas estocásticas con capacidad de manejar el ruido y secuencias temporales, tales como los modelos ocultos de Markov (HMMs) [95].

Cen Rao y otros [97], sostienen que los gestos realizados por humanos se caracterizan por cambios notables en la velocidad y orientación de las trayectorias descritas por los mismos (ver Figura 2.5). Desarrollan un modelo computacional para capturar estos cambios, realizando un análisis de curvaturas en ejes *espacio – tiempo* a partir de trayectorias en 2D. Los puntos de la trayectoria donde se detectan cambios los llaman: *instantes dinámicos*. El cambio dinámico, es una entidad instantánea que ocurre durante un cuadro de imagen, y representa un cambio importante en las características del movimiento. Asimismo, definen un intervalo como el período entre dos instantes dinámicos, y durante el cual las características del movimiento no cambian. A partir de instantes dinámicos e intervalos, los autores identifican gestos realizados por personas, analizando los cambios observados de dirección y velocidad descritos por la trayectoria del movimiento, sin la necesidad de un modelo inicial. Aunque este enfoque no necesita datos de entrenamiento y es invariante a la vista, al igual que el modelo propuesto por Davis [25], requiere de información proporcionada desde varios ángulos de vista para tener una descripción confiable de la trayectoria para cada tipo de gesto.

Krahnstover y otros [59], desarrollan un trabajo para realizar el seguimiento y análisis del movimiento humano para resolver problemas de clasificación. En su enfoque combinan métodos basados en apariencia para representar la información espacial y modelos ocultos de Markov [95] para codificar patrones visuales con variación temporal. Determinan que la integración de características espaciales de bajo nivel y el análisis temporal, proporcionan un enfoque adecuado para realizar la

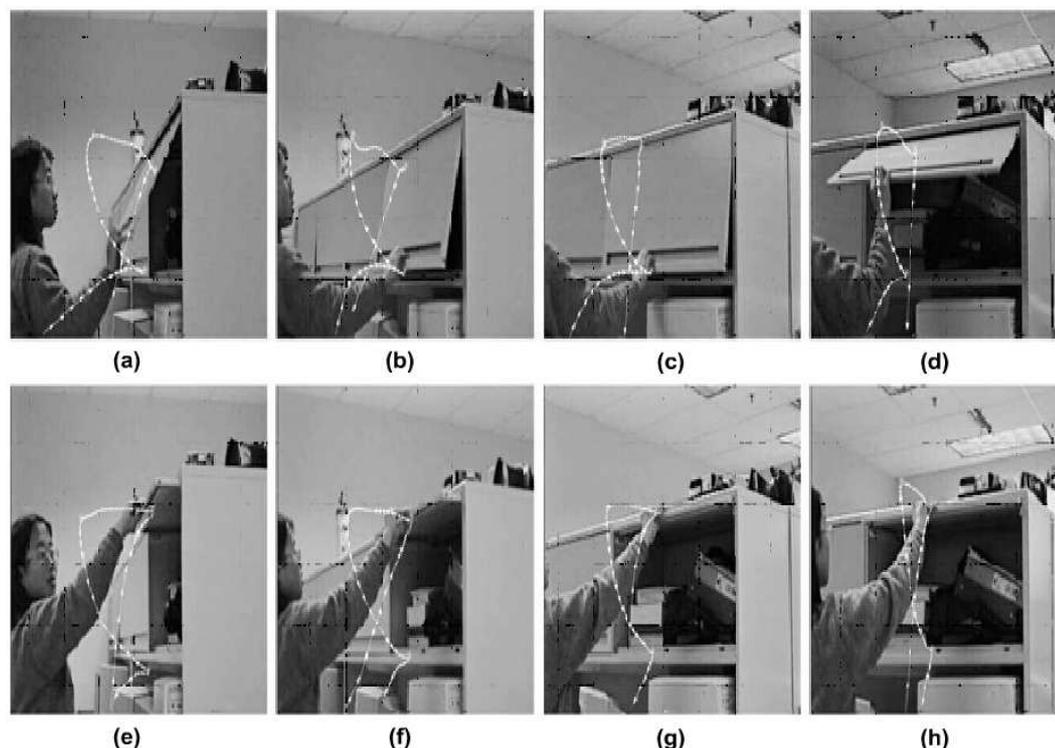


Figura 2.5: Secuencia de imágenes que muestran las trayectorias observadas desde distintos puntos de vista para identificar los gestos de: *abrir gabinete* (imágenes (a)-(d)) y *cerrar gabinete* (imágenes (e)-(h)) [97].

detección, seguimiento y clasificación de gestos humanos. Para cada actividad, colectan un conjunto de secuencias realizadas por diferentes personas. Posteriormente las regiones de interés (empleando movimiento) son detectadas, extraídas como partes de imágenes y escaladas a tamaños predeterminados. A las porciones de imágenes que representan cada clase de actividad, se les aplica extracción de características con el fin de obtener una representación compacta de información espacial. Estas representaciones son proyectadas a un *eigenespacio*<sup>1</sup>, el cual mapea cada secuencia de imágenes a una trayectoria, las que son utilizadas para entrenar a los HMMs [95]. Aunque Krahnstover y otros mencionan que el método desarrollado es eficiente para reconocer varias tareas, no muestran resultados donde indiquen los porcentajes de reconocimiento logrados. Por otro lado, Yang y otros [122], proponen un enfoque para modelar y aprender actividades humanas a partir de observaciones visuales proporcionadas por una cámara de vídeo (aunque por el momento no la utilizan). La intención de su trabajo es proporcionar a sistemas robóticos la capacidad de adquirir habilidades humanas a través de observar humanos realizar sus tareas. Proponen un método basado en HMMs para modelar y reconocer actividades humanas. La actividad humana se representa por trayectorias, escogen como la trayectoria óptima para representar a cada gesto, la obtenida al analizar la realización de cada gesto varias veces. Los autores prueban su sistema definiendo varios dígitos para representar gestos y utilizan el *mouse* como dispositivo de entrada, reportan porcentajes de reconocimiento de hasta 99.78 %, utilizando 100 muestras de cada gesto. Un trabajo similar que utiliza entradas por el *mouse* con el fin de reconocer gestos es desarrollado por Min y otros [71].

<sup>1</sup>En álgebra lineal, los vectores propios, autovectores o eigenectores de un operador lineal son los vectores no nulos que, cuando son transformados por el operador, dan lugar a un múltiplo escalar de sí mismos, con lo que no cambian su dirección. Este escalar recibe el nombre de valor propio, autovalor, valor característico o eigenvalor. A menudo, una transformación queda completamente determinada por sus vectores propios y valores propios. Un espacio propio, autoespacio o eigenespacio es el conjunto de vectores propios con un valor propio común [81].

Los trabajos realizados por [59, 71, 122], aplican HMMs como un medio para modelar actividades humanas complejas. La diferencia entre estos trabajos, consiste principalmente en el vector de características empleado o el tipo de datos que manejan (discretos o continuos), así como la fuente de información (cámaras de vídeo, *mouse*). Sin embargo, el proceso para reconocer el gesto que se está realizando, consiste básicamente en analizar la trayectoria del movimiento a través de explotar el orden natural en que se realiza la actividad humana mediante una representación probabilística basada en estados. Con un entrenamiento apropiado, estos modelos permiten la caracterización eficiente de gestos en una amplia variedad de dominios. Un trabajo interesante es el propuesto por Wang y otros [117], donde desarrolla un enfoque para reconocer gestos utilizando un esquema de estados ocultos discriminativos. Su trabajo reporta el reconocimiento de gestos con una alta probabilidad, no aplica contexto en el proceso de reconocimiento. El uso de información contextual para apoyar el proceso de reconocimiento, permite incrementar de una manera significativa la probabilidad de reconocimiento de la actividad humana, además de disminuir el número de datos de entrenamiento, tal como se demuestra en esta tesis.

El análisis del movimiento humano utilizado para reconocer actividades se emplea generalmente en aplicaciones que tienen que ver con gestos comunicativos, tales como el lenguaje de señas, interacción humano-computadora o enviar comandos a robots. Para reconocer actividades más complejas se tiene que recurrir al manejo de costosos modelos 3D [37]. El uso de información contextual por otro lado, facilita el reconocimiento de la mayoría de las actividades realizadas al interactuar con objetos del entorno.

### 2.3. Reconocimiento de gestos utilizando contexto

Los trabajos que utilizan información relacionada con el ambiente donde se encuentra la persona realizando sus actividades se les conoce como trabajos que emplean información de contexto. Diferentes autores [31, 76, 108] manifiestan que el uso de información contextual permite el reconocimiento de actividades complejas, así como una mayor variedad de las mismas. La información de contexto, adquiere distintas formas dependiendo principalmente de la aplicación. Sin embargo, de manera general cubre los siguientes aspectos:

- Descripción del escenario.
- Descripción de los objetos existentes en el escenario.
- Asignación de atributos a los objetos del escenario.
- Relación entre la persona y los objetos del escenario.

Algunos trabajos que utilizan información contextual para realizar el reconocimiento de actividades humanas son los siguientes:

Ayers y Shah [5], se enfocan a reconocer el comportamiento humano en un ambiente de oficina. Estos autores apuntan que, reconociendo las acciones que realiza una persona y utilizando información de contexto, el comportamiento de la misma queda completamente determinado. La actividad humana que logran identificar, la representan en cuadros de imágenes representativos de la actividad observada en un ambiente de oficina. Indican que, la reducción de una secuencia de vídeo en

### 2.3. Reconocimiento de gestos utilizando contexto



Figura 2.6: Imágenes mostrando los *instantes claves* reconocidos por Ayers y Shah en la realización de los siguientes eventos: (a) *una persona entra*, (b)-(c) *usa la terminal*, (d) *se levanta* y (e) *sale* [5].

un conjunto pequeño de imágenes trae beneficios en el análisis posterior de actividades para diferentes aplicaciones: seguridad y vigilancia entre otras. La información contextual que utiliza Ayers y otros, consiste en una descripción precisa del ambiente bajo observación. El sistema que proponen, necesita conocer la posición exacta de las puertas y de los objetos de interés (computadora, cajones, teléfono) existentes en la oficina. Los lugares donde se espera que exista algún tipo de actividad se marcan con colores. La actividad se reconoce al detectar variaciones de iluminación en los sitios previamente marcados, después que se sigue a la persona utilizando el centroide de la cabeza y su proximidad con las regiones de posible actividad.

El sistema propuesto por Ayers para reconocer actividades humanas se apoya en una máquina de estado finito, donde las transiciones entre estados son deterministas. El nodo de inicio es la parte del ambiente especificado como: entrada o salida, de esta forma, el proceso inicia al detectar a una persona aparecer por dicho sitio. Tanto la detección, como el seguimiento de la persona se basa en el color de piel. El sistema confía plenamente en los cambios detectados en la escena para suponer que una acción se está realizando. Si una persona cambia el *mouse* de lugar, el sistema considera que se está utilizando la computadora, por la simple razón de estar cerca de la computadora y haber movido el *mouse*. El sistema no permite el cambio de posición de los objetos, si se utiliza el teléfono, éste debe regresar a la posición original para que la actividad *hablando por teléfono* pueda ser reconocida. El trabajo propuesto por Ayers y Shah presenta varias limitaciones, además, al basar su proceso de reconocimiento en un autómata determinista no es capaz de manejar la incertidumbre presente en la gran mayoría de los ambientes reales. La Figura 2.6 muestra un ejemplo de operación del sistema propuesto por Ayers y Shah.

De manera similar al trabajo propuesto por Ayers, Olson y Brill [82] desarrollaron un sistema para aplicarse en interiores (ambientes controlados) y con fines de seguridad. El sistema puede

detectar eventos tales como *entrando*, *saliendo* y *depositando un objeto*. Para esto, elaboran un mapa del cuarto donde las regiones de interés son etiquetadas y se usan para saber por dónde se desplaza una persona. El sistema *aprende* la posición de entradas y salidas. Los eventos importantes son detectados y su ocurrencia tiene lugar en ciertos lugares y en ciertos momentos. El sistema reconoce el comportamiento de una persona (eventos relevantes) al detectar la presencia de la misma cerca de regiones consideradas de interés. La detección de una persona se realiza mediante la sustracción de imágenes, el seguimiento lo basan en un proceso de estimación por filtro de Kalman. Al igual que el trabajo desarrollado por Ayers, este trabajo asume que se está realizando una actividad, basándose en la cercanía de la persona con regiones de interés, lo cual no es muy confiable.

Por su parte, la detección de objetos móviles (especialmente personas) y el análisis de su comportamiento en un ambiente de supervisión y seguridad, es el trabajo desarrollado por Rota y Thonnat [108]. Thonnat propone un esquema general basado en conocimiento, utiliza información *a priori* relacionada al uso de escenarios predefinidos así como una descripción exacta de los objetos en la escena (ver Figura 2.7). El formalismo que proponen está basado en el uso de un árbol de *aridad n* con el fin de declarar eventos, y en lógica temporal para declarar las aplicaciones dependientes de los escenarios. Al igual que Ayers, Thonnat reconoce eventos al detectar los cambios observados en el escenario en distintos intervalos de tiempo, para esto utilizan información como: *posición relativa*, *distancia* y *tiempo*. Con base en eventos observables y escenarios, determinan el comportamiento de una persona como: *normal* o *anormal*. Básicamente, el problema de reconocer eventos se reduce al problema de encontrar un conjunto de estados que describa un escenario con suficiente exactitud. El enfoque propuesto, aunque funciona de manera satisfactoria en algunos escenarios presenta algunas limitaciones. El sistema es incapaz de manejar la incertidumbre ocasionada por aspectos de visión tales como: oclusiones y sombras, ya que emplean un valor de umbral fijo tomando como referencia la imagen actual, al aplicar la sustracción de imágenes para detectar a una persona en el escenario. Esto puede originar interpretaciones erróneas al determinar distancias entre persona y equipo en la descripción de alto nivel. Los parámetros utilizados por Thonnat y Rota [108] en su trabajo, son determinados por conocimiento experto. Lo recomendable en sistemas que aplican visión, es emplear técnicas de aprendizaje para determinar los parámetros en la etapa de configuración a partir de datos de entrenamiento, de tal manera que estos sistemas tengan un mayor margen de aplicaciones.

A diferencia de los trabajos realizados por Ayers, Olson y Thonnat [5, 82, 108], el trabajo que se propone en esta tesis emplea una técnica probabilística para reconocer gestos, permitiendo con esto el manejo de incertidumbre (aspecto presente en la mayoría de los ambientes reales). Asimismo, se emplea una combinación de técnicas de segmentación basada en color y movimiento durante la fase de detección, con el fin de determinar regiones de piel en movimiento dentro de un escenario. Esta combinación, hace posible enfrentar aspectos de iluminación variables, condición presente en escenarios del mundo real.

## 2.4. Reconociendo la interacción humana

Para capturar la interacción humana descrita al manipular objetos del entorno de una manera confiable, es necesario realizar la combinación de los dos enfoques anteriores: modelar los gestos basados en el análisis del movimiento y utilizar información contextual. En esta sección, se analizan algunos trabajos que realizan el reconocimiento de actividades humanas utilizando el análisis de movimiento e información de objetos del escenario.

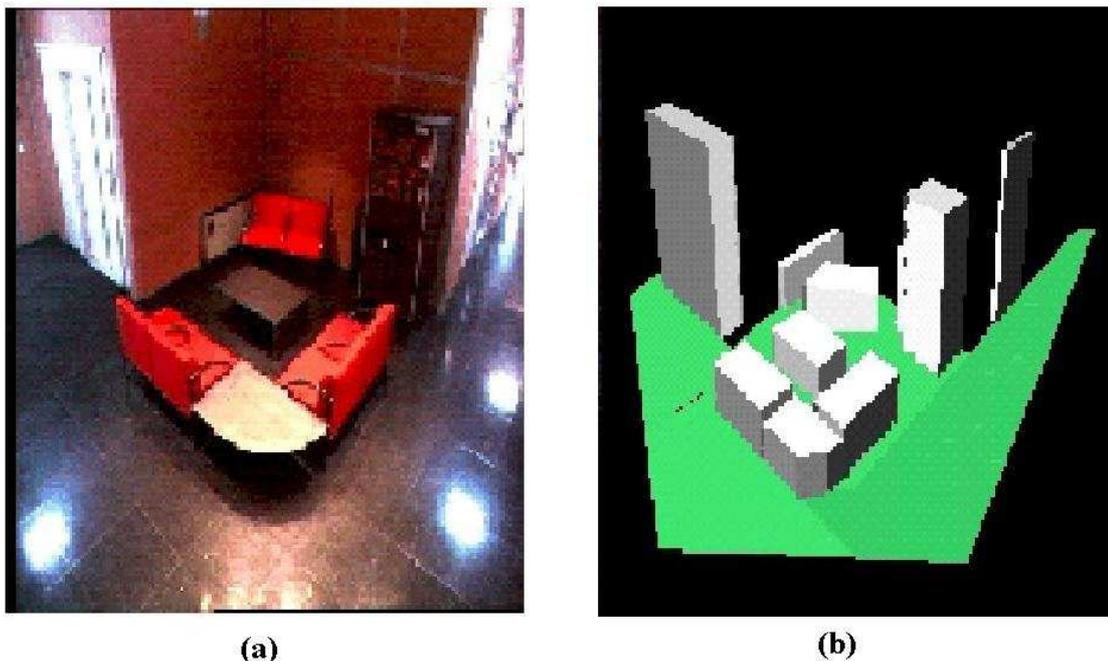


Figura 2.7: Imagen que muestra uno de los escenarios utilizados por Thonnat [108] como información previa. Imagen (a): presenta a una cafetería ubicada en una estación de metro mostrando algunos objetos de interés, Imagen (b): ilustra el modelo 3D de la cafetería observada en la imagen (a) .

Uno de los primeros trabajos que integran el uso de información contextual y análisis de trayectorias descritas por el centroide de la mano al manipular objetos, es el propuesto por Darnell y otros [76]. El modelo que proponen aprovecha el análisis del movimiento humano así como de información contextual, con fin de realizar el reconocimiento de acciones y la clasificación de objetos. Para clasificar objetos emplean un método donde describen las propiedades físicas del objeto, así como las acciones asociadas al mismo; formando con esta información *clases* de objetos (ver Figura 2.8). Su trabajo demuestra que los objetos pueden ser detectados y clasificados a través de reconocer las acciones asociadas a los mismos. Aplican un enfoque bayesiano para analizar la evidencia colectada por su método con el fin de reconocer actividades y clasificar objetos desconocidos. El enfoque que proponen relaciona el movimiento de la mano e información contextual para realizar:

- el reconocimiento de acciones usando información contextual y,
- el reconocimiento de objetos usando información de acciones.

Este trabajo, realiza el reconocimiento de los gestos basado en la apariencia del objeto y clasifica objetos de manera indirecta a través del reconocimiento de gestos. Aplican modelos ocultos de Markov (HMMs) para representar las acciones asociadas a los objetos. Para entrenar a los HMMs utilizan solamente información de la posición  $(x, y)$  del centroide de la mano al realizar un gesto determinado. La interacción con un objeto la determinan al considerar cierto tiempo de traslape entre la ventana de la mano y la del objeto. Una vez que el contacto con el objeto se ha determinado, se realiza el análisis de la trayectoria de la mano y se comparan con los modelos HMMs asignados al objeto en cuestión. Emplean métodos bayesianos para obtener una clasificación de objetos desconocidos, para ello utilizan las acciones detectadas con las características extraídas de los objetos. Mencionan que su

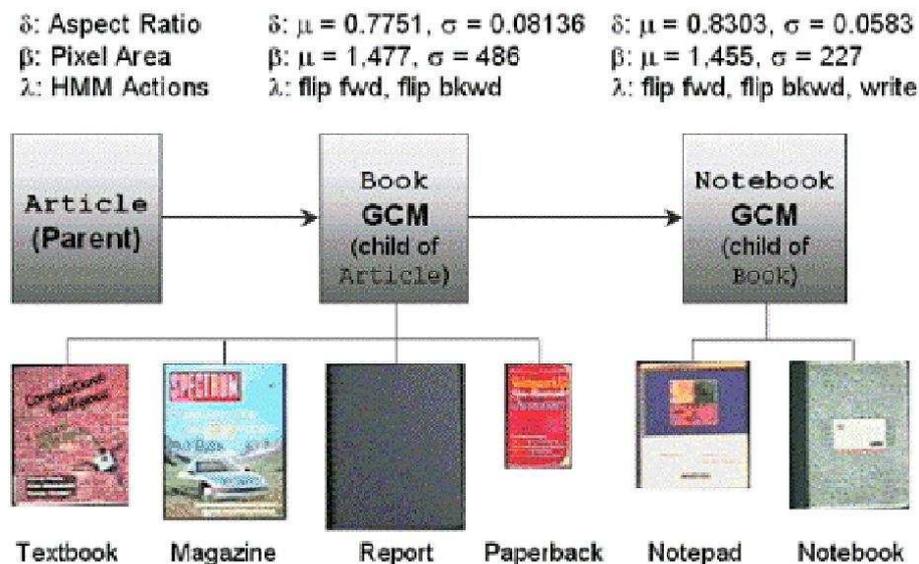


Figura 2.8: Imagen que muestra el esquema empleado por Darnell para reconocer clases de objetos [76]. Darnell aplica un enfoque orientado a objetos para describir clases y jerarquías de clases basado en un esquema denominado: Modelo General de Clases o GCM. La imagen muestra el GCM para la clase libro y cuaderno, las plantillas se obtienen a partir de ejemplos. El GCM ofrece una organización jerárquica para los tipos de datos. Asimismo, a cada clase asocia los gestos permitidos ( $\lambda$ ).

enfoque es adecuado para localizar y clasificar objetos conocidos y desconocidos bajo una variedad de condiciones incluyendo oclusión. Por el momento su trabajo se limita en determinar la interacción entre una persona y un objeto. Utilizan la información proporcionada por una cámara ubicada en la parte superior del escenario, lo que facilita la detección y seguimiento de las manos para reconocer acciones cuando la persona está sentada en un escritorio e interactuando con objetos a su alcance: revistas, libros, cuadernos, etc. (ver Figura 2.9).

Reportan el reconocimiento de objetos desconocidos con un porcentaje de 87.6%. Asimismo, sostienen el reconocimiento de 46 gestos distintos realizados con la mano al interactuar con objetos del entorno, con un porcentaje de 90.2%. En el trabajo que proponen, asumen que una vez detectado el contacto de la mano con uno de los objetos del entorno, éste permanece en contacto y se sugiere la evaluación de modelos HMMs específicos. Esta consideración puede dar lugar a error en el proceso, ya que la mano puede permanecer en contacto con el objeto un período determinado y posteriormente realizar una acción con otro objeto. A diferencia del enfoque de Darnell, el modelo que se propone en este trabajo emplea la información contextual relacionada con los objetos como parte de las características de entrenamiento lo cual ofrece una mayor confiabilidad en el proceso de reconocer los gestos realizados. El modelo desarrollado obtiene un porcentaje de reconocimiento de gestos en uno de los escenarios de 99.57% [73].

Fritsch y otros [31] proponen un trabajo para reconocer gestos manipulativos. Se enfocan principalmente al reconocimiento de gestos realizados al interactuar las manos de una persona con objetos del entorno en un escenario de ensamble (ver Figura 2.10). El sistema está orientado al diseño de interfaces *humano – computadora* proactivas, habilitando a los sistemas a observar las actividades humanas realizadas en un escenario y reaccionar de forma apropiada. Para realizar el reconocimiento de los gestos, analizan los datos obtenidos a partir de la trayectoria del movimiento de las manos a través de una secuencia de imágenes. Se apoyan en información contextual para mejorar el reconocimiento de gestos, ya que los gestos realizados en una aplicación de ensamble no son descritos por



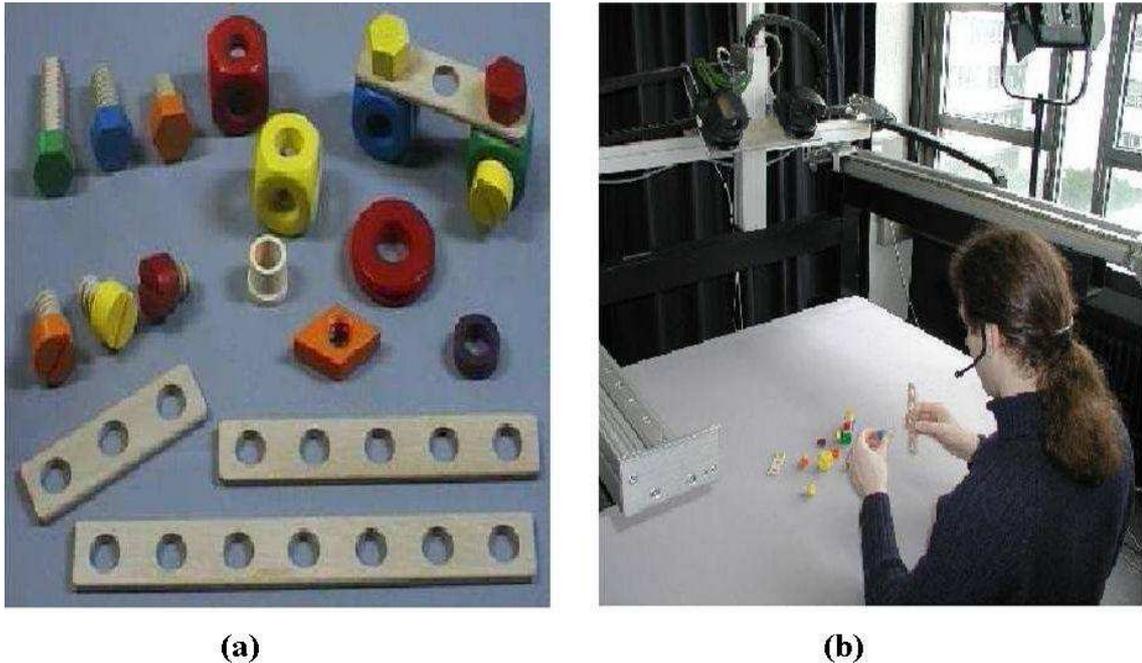


Figura 2.10: Imágenes utilizadas por Fritsh [31] para reconocer gestos manipulativos. La imagen (a) muestra las piezas que utiliza para simular un escenario de ensamble. Imagen (b) muestra la manipulación de las piezas con fines de ensamble.

nes a estos sistemas. El modelo que se propone en este trabajo, toma en cuenta esta consideración y extiende el proceso de clasificación de los gestos incluyendo la toma de decisiones, aproximando la solución de un proceso de decisión de Markov parcialmente observable (POMDP) de horizonte finito, a través de una red de decisión dinámica.

## 2.5. La utilidad de los gestos

Existen trabajos recientes que buscan extender la clasificación de gestos y decidir qué hacer con los gestos reconocidos. Estos enfoques ofrecen una amplia variedad de aplicaciones a los trabajos de reconocimiento de gestos basados en visión. Uno de los primeros trabajos realizados bajo este enfoque es el propuesto por Hoey y otros [43].

Hoey y otros [41] presentan un sistema adaptable basado en visión y teoría de decisiones, el cual aprende a reconocer comportamientos a partir de observar gestos faciales. Es decir, el sistema aprende a relacionar los movimientos del rostro humano a partir del contexto en el cual actúan y una función de utilidad. El sistema propuesto se basa en un proceso de decisión de Markov parcialmente observable (POMDP) y una red bayesiana dinámica (RBD). Las expresiones faciales de una persona capturada a través de video forman las observaciones que son integradas al sistema utilizando una RBD. La RBD genera las condiciones de abstracción espacial-temporal necesarias para tomar decisiones de alto nivel. Se emplea un tipo específico de RBD, representada por modelos ocultos de Markov acoplados (CHMMs), los cuales determinan la expresión facial más probable. Hoey aplica un método de aproximación para obtener políticas de acción basadas en expresiones faciales. Bajo el paradigma de agentes Hoey y otros prueban el sistema en un dominio de juego donde participan dos agentes, uno de los agentes aprende el comportamiento del otro observando sus expresiones faciales y las acciones

realizadas. En este trabajo, el contexto se refiere a las acciones observables de los agentes. El trabajo presentado por Hoey no realiza consideraciones previas de los tipos de comportamientos que pueden estar presentes en un escenario. Sin embargo, aunque Hoey habla de aprender los parámetros de un POMDP mientras descubre tipos de comportamientos, por el momento sus resultados se restringen al uso de procesos de decisión de Markov (MDPs). El trabajo de Hoey se aplica básicamente para la clasificación de gestos.

Hoey y otros [43], han participado de manera reciente en el desarrollo de trabajos donde se monitorean a personas con discapacidad o de edad avanzada, para apoyarlas en la realización de sus tareas [11, 42, 114]. En estos trabajos, se asume el comportamiento de una persona basándose en la cercanía de la persona con regiones de interés fijas y previamente establecidas. Al no realizar un análisis detallado de la actividad humana la confiabilidad en el proceso de reconocimiento disminuye. El tratamiento es parecido al realizado por Ayers [5]. Además Boger [11], simplifica el proceso de detección y seguimiento de las manos utilizando un método intrusivo (brazaletes), lo cual no es muy adecuado para personas con deficiencia mental. Aunque manejan aspectos de incertidumbre en sus trabajos en relación al comportamiento de la persona (estados del mundo), el uso de MDPs sugiere una completa observabilidad en los estados. En trabajos recientes realizado por Montero y Sucar [74, 75], se aplica un enfoque que integra contexto para mejorar el reconocimiento de gestos manipulativos y permite tomar decisiones en dos escenarios diferentes: (i) videoconferencias y (ii) apoyo a discapacitados. La toma de decisiones se basa en redes de decisión dinámicas para aproximar soluciones a problemas POMDPs con horizonte finito.

## 2.6. Resumen del capítulo

Los trabajos relacionados al reconocimiento automático de gestos o actividades humanas, se pueden dividir en tres grupos tomando como referencia el uso de información contextual en: a) Trabajos que no utilizan información contextual y basan su reconocimiento en el análisis de movimiento, b) Trabajos que utilizan información contextual y basan su reconocimiento principalmente en el uso de información de escenarios y, c) Trabajos que integran información de movimiento y de contexto para reconocer gestos. Los trabajos que pertenecen al primer grupo se limitan al reconocimiento de gestos simples: *caminar*, *correr*, *saltar*, *sentarse*, o de carácter comunicativo (lenguajes de señas). Por otro lado, los trabajos que utilizan información contextual tienen una mayor variedad de reconocimiento, ya que gran parte de las actividades realizadas por humanos en distintos escenarios tiene que ver con la manipulación de objetos del entorno. Los trabajos que se basan principalmente en el uso de información contextual [5, 82, 108] confían en una descripción exacta del escenario, y se apoyan en relaciones de distancia o tiempo, o bien en máquinas de estado finito, para determinar la actividad. Estos enfoques son incapaces de manejar la incertidumbre ocasionada por aspectos de visión tales como: oclusiones y variación luminosa, por lo que son aplicados bajo serias restricciones. Estas limitaciones son enfocadas por los trabajos que pertenecen al tercer grupo [31, 76], los cuales realizan un análisis detallado, tanto de los objetos presentes en el escenario como del movimiento humano. Sin embargo, debido a su elevado nivel de complejidad con fin de obtener la robustez necesaria en el reconocimiento, en algunos de estos trabajos [31], no es muy factible su uso en aplicaciones de tiempo real. Es necesario desarrollar sistemas que integren aspectos de análisis del movimiento así como de información contextual con el fin de crear esquemas confiables para el reconocimiento de gestos, y al mismo tiempo no sean tan costosos para poder aplicarlos en ambientes reales. Además, los trabajos mencionados presentan una limitante, su alcance es a nivel de clasificación, es decir, simplemente reconocen un gesto o actividad, siendo la mayoría de ellos incapaces de decidir qué hacer una vez

que reconocen el gesto. Existen trabajos recientes que extienden la etapa de clasificación y permiten la toma de decisiones utilizando generalmente enfoques MDPs. Sus alcances son limitados al no considerar la incertidumbre proveniente del comportamiento humano obtenido por cámaras de vídeo. Algunos de estos trabajos simplifican esta incertidumbre al emplear métodos intrusivos con el fin de manejar modelos completamente observables.

El enfoque propuesto en esta tesis, combina el uso de información contextual y análisis de movimiento para reconocer los gestos realizados por una persona al interactuar con objetos del entorno. El análisis del movimiento está basado en modelos ocultos de Markov, técnica robusta que permite el análisis temporal, característico de los gestos. La información de contexto se integra en la etapa de entrenamiento de los HMMs, esto mejora el proceso de reconocimiento, ya que la información del objeto está asociada a la trayectoria del gesto. Esta integración permite un esquema de reconocimiento sencillo y eficiente, en ambientes donde el número de objetos presentes es limitado, característica de la mayoría de los ambientes reales. Asimismo, este trabajo extiende la etapa de clasificación y presenta un nuevo enfoque para la toma de decisiones basada en la información visual del comportamiento humano. A diferencia de los trabajos realizados por Hoey y Boger, este enfoque integra información contextual para apoyar el proceso de reconocer la actividad humana, lo cual permite enfrentar el aspecto de incertidumbre en los estados del mundo con mayor confiabilidad. La aproximación de soluciones a problemas POMDPs es manejada utilizando redes de decisión dinámicas, técnica novedosa que permite tratar problemas de decisión dinámica analizando un determinado número de etapas temporales, y decidir la elección de una acción basándose en la máxima utilidad esperada.

# Capítulo 3

## Procesos de Decisión de Markov

Decidir de manera automática la mejor vista para mostrar a la audiencia en un escenario de videoconferencia basados en la observación visual de los gestos del expositor, o proporcionar instrucciones audibles para que una persona con discapacidad pueda completar una tarea, son problemas de toma de decisiones. La toma de decisiones bajo condiciones de incertidumbre en sistemas dinámicos estocásticos, ha sido un área de trabajo relevante en las comunidades de teoría de control e investigación de operaciones y de manera reciente en inteligencia artificial y visión por computadora. En este capítulo, se van a abordar algunas técnicas traídas de la comunidad de investigación de operaciones (IO), para enfrentar el problema de tomar acciones óptimas en dominios estocásticos parcialmente observables. La Sección 3.1 presenta a los procesos de decisión de Markov (MDPs), técnica aplicada para tomar decisiones en ambientes observables. Posteriormente, en la Sección 3.2 se describen los procesos de decisión de Markov parcialmente observables (POMDPs). Las redes bayesianas dinámicas (RBDs) son mostradas en la Sección 3.3. Las redes de decisión (RDs) o diagramas de influencia (DIs), son métodos que extienden a las RBs y permiten tomar decisiones se muestran en la Sección 3.4. En la Sección 3.5, se describen a las RDDs, técnica que extiende a las RBDs y que aproximan soluciones a problemas POMDPs de horizonte finito. Finalmente, en la Sección 3.6 se presenta un resumen del capítulo.

### 3.1. Procesos de decisión de Markov

Los procesos de decisión de Markov (MDPs) aparecen como un formalismo apropiado para modelar tareas de planeación y toma de decisiones en dominios estocásticos [93]. Es decir, dado un modelo del mundo correcto y completo, además de una estructura de recompensa, los MDPs encuentran la manera óptima de comportarse (seleccionar acciones). El mundo puede observarse, en algún instante determinado, estando en alguno de los  $n$  (bien definidos) estados que lo describen. En un MDP, el sistema interactúa con el mundo (ver Figura 3.1), tomando estados como entradas y generando acciones como salida, aunque existe incertidumbre en el efecto de las acciones hacia los estados, estos siempre son observables. Un MDP se describe formalmente por la tupla  $\{S, A, T, R\}$ , donde:

- $S$ , es un conjunto finito de estados que describen al mundo.
- $A$ , es un conjunto finito de acciones  $a$  disponibles al sistema.

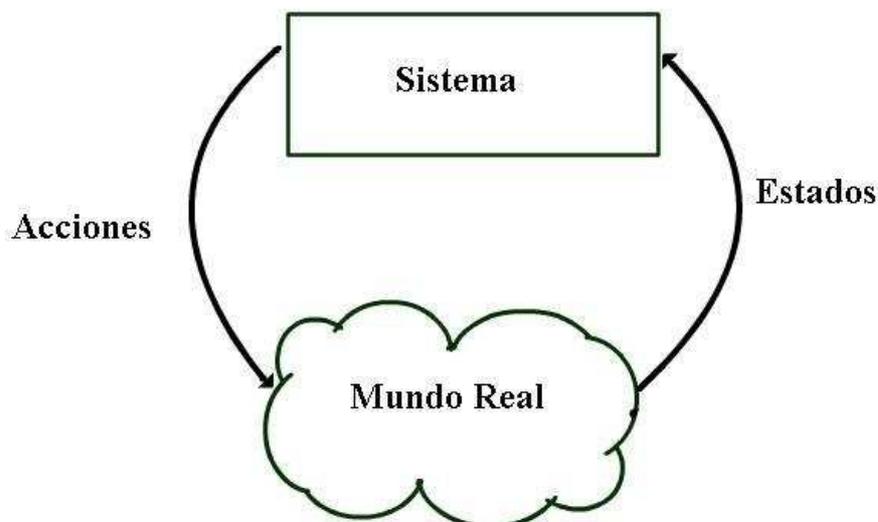


Figura 3.1: Un proceso de decisión de Markov modela la interacción entre el sistema y el mundo.

- $T : S \times A \rightarrow \Pi(S)$ , define la función de transición de estados, dando para cada estado del mundo y cada acción del sistema, una distribución de probabilidades para los estados. Definimos como  $T(s', s, a)$ , la probabilidad de pasar del estado  $s$  al  $s'$ , al realizar la acción  $a$  en el estado  $s$ .
- $R : S \times A \rightarrow \mathfrak{R}$ , especifica la función de recompensa, proporciona la recompensa inmediata que el sistema obtiene al seleccionar cada acción en cada estado, definimos como  $R(s, a)$  la recompensa esperada por tomar la acción  $a$  en el estado  $s$ .

Los MDPs se rigen por la propiedad Markoviana, la cual especifica que el estado siguiente ( $t + 1$ ) y la recompensa esperada sólo dependen del estado y acción actuales ( $t$ ). En estos modelos, la idea es realizar acciones maximizando alguna medida de la recompensa recibida a largo plazo. Para esto, se consideran dos opciones: sistemas con horizonte finito y sistemas con horizonte infinito. Al considerar un horizonte finito, el sistema debe maximizar la suma de las recompensas que se obtendrán en los siguientes  $k$  pasos, maximizando la expresión:

$$E \left[ \sum_{t=0}^{k-1} r_t \right] \quad (3.1)$$

donde  $r_t$  es la recompensa recibida en el paso  $t$ . Aunque varios autores [19, 105] evitan usar el modelo de horizonte finito, alegando que encontrar un valor apropiado para  $k$  es difícil, existen algunas aplicaciones (video conferencias) [75] donde, la selección de acciones analizando un determinado número de etapas temporales, es suficiente para obtener resultados satisfactorios.

El siguiente enfoque (sistemas con horizonte infinito) considera que el sistema debe actuar por siempre, en lugar de considerar un tiempo determinado. En este enfoque, se emplea el modelo de horizonte infinito con descuento, donde se suman las recompensas sobre un tiempo infinito de operación del sistema, pero considerando un *factor de descuento*  $0 < \gamma < 1$ , con el fin de ponderar la recompensa obtenida en cada etapa y garantizar que la suma sea finita. En este caso el sistema debe optimizar:

$$E \left[ \sum_{t=0}^{\infty} \gamma^t r_t \right] \quad (3.2)$$

bajo este esquema, las recompensas recibidas en las primeras etapas tienen más valor para el sistema.

Una política es una descripción del comportamiento del sistema. Existen dos tipos de políticas: estacionarias y no estacionarias. Una *política estacionaria*  $\pi : S \rightarrow A$ , especifica una acción para cada estado, donde la elección de la acción sólo depende del estado. Una *política no estacionaria* considera una secuencia de *situación - acción*, indexadas por el tiempo. En un modelo con horizonte finito, la manera que se elige la acción en la última etapa de tiempo, es muy diferente, si se considera un tiempo infinito hacia adelante. En el caso de modelos con horizonte infinito, siempre existe una cantidad de tiempo remanente que se puede asumir constante, por lo tanto, no hay razón para cambiar de estrategia: existe una política estacionaria óptima. Una política puede ser evaluada basada en el valor que se espera obtener a largo plazo al ser ejecutada. En el caso de horizonte finito,  $V_{\pi,t}(s)$  indica la suma de la recompensa esperada, obtenida al iniciar en el estado  $s$  y ejecutar la política no estacionaria  $\pi$  por  $t$  pasos.  $V_{\pi,t}(s)$  puede definirse de manera inductiva como

$$V_{\pi,t}(s) = R(s, \pi_t(s)) + \gamma \sum T(s, \pi_t(s), \hat{s}) V_{\pi,t-1}(\hat{s}) \quad (3.3)$$

la cual obtiene el valor en la etapa temporal  $t$ , de estar en el estado  $s$  y ejecutar la política no estacionaria  $\pi$ , como la recompensa inmediata  $R(s, \pi_t(s))$ , mas el valor esperado en los siguientes  $t - 1$  pasos. Para evaluar las etapas futuras se consideran todos los posibles estados resultantes  $\hat{s}$ , la probabilidad de su ocurrencia  $T(s, \pi_t(s), \hat{s})$ , y su valor  $V_{\pi,t-1}(\hat{s})$  en el paso  $(t - 1)$  al aplicar la política  $\pi$ . La obtención de la función de valor para el caso de horizonte infinito es similar al descrito. Se ha mostrado cómo obtener la función de valor dada una política, algunas veces se necesita el proceso inverso, es decir, obtener una política a partir de una función de valor. Existen varios métodos para obtener políticas óptimas en MDPs, algunos de los más conocidos son los métodos de *iteración de valor* [8] e *iteración de políticas* [45].

## 3.2. Procesos de decisión de Markov parcialmente observables

Los procesos de decisión de Markov parcialmente observables (POMDPs) [93], son una extensión a los MDPs, donde además de existir incertidumbre en el efecto de las acciones sobre los estados del mundo, también existe incertidumbre en los estados del mundo. Para comportarse de manera adecuada en un mundo parcialmente observable, es necesario utilizar memoria para las acciones y observaciones previas, con el fin de disminuir la ambigüedad de los estados [19]. Los POMDPs son un enfoque que proporcionan un método sistematizado para que un sistema se comporte de manera apropiada en un mundo parcialmente observable [118].

Un proceso de decisión de Markov parcialmente observable se describe por la tupla  $\{S, A, T, R, \Omega, O\}$ , donde

- $S, A, T$ , y  $R$  describen a un proceso de decisión de Markov,

- $\Omega$ , conjunto (finito) de observaciones a través del cual se percibe el mundo,
- $O : S \times A \rightarrow \prod(\Omega)$ , define la *función de observación*, la cual proporciona para cada acción y estado resultante, una distribución de probabilidad sobre las posibles observaciones (se define como  $O(s, o, a)$ , la probabilidad de percibir la observación  $o$  después de tomar la acción  $a$  y pasar al estado  $s$ ).

Al igual que en un MDP, también se especifica un factor de descuento  $\gamma$ , el cual indica la cantidad que afecta al valor de recompensa en el futuro. El objetivo de un problema representado por un POMDP, es maximizar la suma total de la recompensa esperada  $E [\sum_{t=0}^k \gamma^t r_t]$ , donde  $k$  especifica la longitud en un problema de horizonte finito, el cual tiende a  $\infty$  para un horizonte infinito. Debido a que en un POMDP el estado del mundo no se percibe completamente, no es posible obtener una política óptima basándonos sólo en esta información. Es necesario mantener un registro de la secuencia completa de acciones y observaciones, o suficiente información estadística, con el fin de actuar de manera óptima.

Una estadística suficiente es *el estado de creencia*  $b$ , el cual es un vector de longitud  $|S|$  cuyos elementos  $b_i = b(s_i)$  indican la creencia de estar en el estado  $s_i$ . Después de tomar alguna acción  $a$  y ver la observación  $o$ , el controlador actualiza su estado de creencia utilizando la Regla de Bayes:

$$b'(s) = P(s|a, o, b) = \frac{O(s, o, a) \sum_s k(s, s, a) b(s)}{P(o|a, b)} \quad (3.4)$$

El denominador,  $P(o|a, b)$ , se obtiene por la suma del numerador sobre todos los valores de  $s$ . Seguido se hace referencia a la función que retorna el valor de  $b'$  como el estimador de estado  $SE(b, a, o)$ . Buscando soluciones, se puede transformar un problema POMDP en un MDP de estados de creencia [53]. Bajo esta transformación, los estados de creencia  $b$  se convierten a estados (continuos) de un MDP. Las acciones no se modifican en esta transformación, sin embargo, las funciones de transición y de recompensas son transformadas a través de la siguiente modificación a la ecuación de Bellman:

$$V^*(b) = \max_a \left[ \sum_s b(s) R(s, a) + \gamma \sum_o P(o|a, b) V^*(SE(b, a, o)) \right] \quad (3.5)$$

Como en cualquier MDP, la política óptima que se trata de aprender es un proceso voraz en relación a la función de valor óptima  $V^*$ . El problema, es que existe un número infinito de estados de creencia continuos, así que, resolver esta ecuación se convierte en un problema difícil. Las soluciones exactas para un problema de *horizonte finito*, toman ventaja al hecho de que las funciones de valor para un MDP de creencia de *horizonte finito* son lineales y convexas, así que pueden representarse por un número finito de hiperplanos en un espacio de *valor-creencia* (ver Figura 3.2).

Al ser lineal y convexa, la función de valor puede ser representada como un conjunto de vectores conocidos como *vectores-alfa*. El valor de un estado de creencia, es el valor máximo obtenido del producto punto del vector que representa las probabilidades sobre los estados, y alguno de los *vectores-alfa* que estructuran la función de valor. Para un horizonte de longitud 1, los *vectores-alfa*

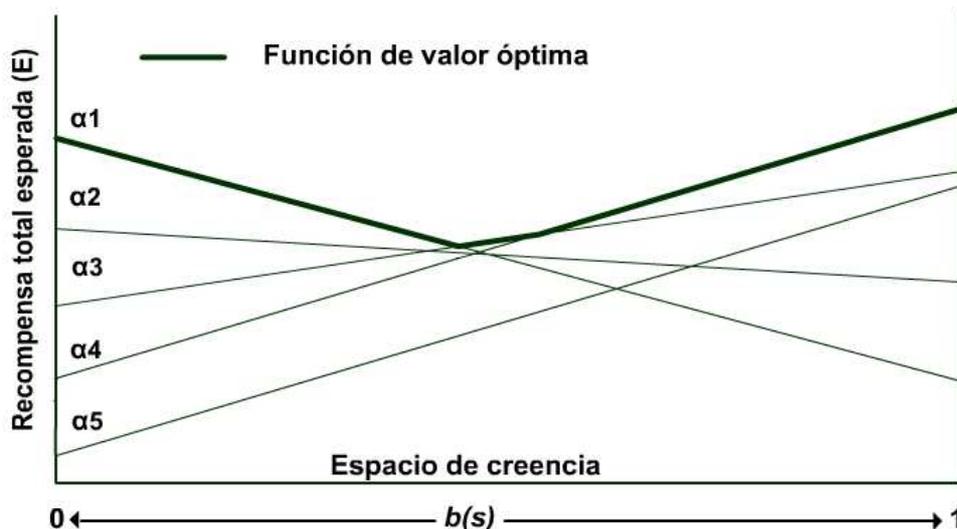


Figura 3.2: Ilustración geométrica de la función de valor para un POMDP de dos estados. Se observa la representación de la función de valor por un conjunto de *vectores-alfa* ( $\alpha_1, \alpha_2, \alpha_3, \alpha_4, \alpha_5$ ). El eje horizontal representa el espacio de creencias  $s$  determinado por la probabilidad  $b(s)$ .

son simplemente el conjunto de vectores que describen las recompensas inmediatas al realizar una acción en un estado de creencia (el cual a su vez depende de las recompensas en estados individuales, así como de la probabilidad de estar en cada estado).

Asimismo, para un horizonte de longitud 2, el problema ahora se convierte en cómo generar el siguiente conjunto de *vectores-alfa*,  $V'$ , a partir del conjunto actual  $V$  de *vectores-alfa*. Considerando que una acción ha sido seleccionada, la recompensa para realizar la siguiente acción depende de la observación que está siendo observada. Una estrategia se define como un mapeo entre observaciones y acciones, así que, si una cierta observación es vista, la acción definida por la estrategia es la mejor opción que se puede tomar. A través de todos los puntos de creencia, varias estrategias diferentes pueden ser apropiadas. Estas estrategias, definen otro conjunto de *vectores-alfa* lineales y convexos que tienen la función de valor para el horizonte de longitud 2, dada una acción específica tomada en el primer paso. Ya que las funciones de valor deben ser definidas sobre todas las posibles primeras acciones, el proceso de definir estrategias se repite para cada posible primera acción. Los vectores resultantes se combinan para generar la actual función de valor de horizonte 2 sobre todo el espacio de creencias. Muy seguido, un subconjunto de vectores-alfa son descartados al ser dominados por otros vectores-alfa, ya que nunca podrían generar un producto punto máximo.

Este proceso que se acaba de mencionar para un horizonte de longitud 2, se repite de forma creciente conforme la longitud del horizonte aumenta. Ya que todos los posibles puntos de creencia no pueden ser enumerados, se han propuesto varios algoritmos [62, 105, 126] con el fin de determinar las regiones sobre las cuales aplicar diferentes vectores para la función de valor. En el peor caso, la complejidad computacional al determinar una política para un MDP de horizonte infinito y con descuento es  $O(|S|^2|A| + |S|^3)$  para cada iteración del algoritmo de iteración de valor o de política. La complejidad de encontrar una política óptima para un POMDP con horizonte finito y con descuento, es exponencial al número de estados y longitud del horizonte. Para un POMDP con horizonte infinito, el problema es indecidible [36].

Encontrar la solución exacta a un problema POMDP de horizonte finito se ha demostrado que es un problema NP-duro, y para el caso de horizonte infinito el problema es aún peor (revisado en

[39]). Estos problemas han propiciado que varios investigadores examinen métodos de solución aproximados. Algunos de los cuales se han dedicado a buscar alternativas para aproximar la función de valor [112], las recompensas o acciones [12]. Ya que, el número de estados y la longitud del horizonte tienen una influencia decisiva para determinar la complejidad de problemas MDP y POMDP, propuestas recientes se enfocan al desarrollo de métodos para factorizar o abstraer estados con el fin de asegurar representaciones compactas [14, 42] y tratar de disminuir la dimensionalidad del espacio de estados. Algunos métodos utilizados para aproximar soluciones a problemas POMDP aplican redes bayesianas dinámicas (RBDs) [26, 49], diagramas de influencia o redes de decisión (RDs) [13, 45], y redes de decisión dinámicas (RDDs) [101].

## 3.3. Redes bayesianas dinámicas

Debido a que los modelos POMDPs son distribuciones probabilísticas, la dinámica de un ambiente POMDP se puede representar mediante una red bayesiana dinámica (RBD). Las RBDs son modelos probabilistas que permiten la representación de variables estocásticas con variación temporal. Asimismo, son estructuras que permiten modelar procesos dinámicos, se basan en las redes bayesianas [88].

### 3.3.1. Redes bayesianas

Una de las representaciones factorizadas empleadas para disminuir la dimensionalidad del espacio de estados al realizar tareas para actualizar los estados de creencia en un POMDP son las redes bayesianas. Las redes bayesianas (RBs) [88], son grafos acíclicos dirigidos formados por nodos que representan variables aleatorias y arcos que indican dependencias probabilísticas entre ellas. La estructura de una RB es un grafo, que muestra la relación cualitativa de las interacciones entre el conjunto de variables que modelan. La estructura del grafo permite la representación de la estructura causal del dominio modelado. Asimismo, una RB permite representar la relación cuantitativa entre las variables modeladas. Numéricamente, esto representa la distribución de probabilidad conjunta entre las variables. La distribución de probabilidad se describe de forma eficiente, explorando las independencias probabilísticas entre las variables modeladas. Cada nodo es descrito por una distribución de probabilidad condicional a través de sus predecesores directos (nodos padre). Los nodos que no tienen padres son descritos por una distribución de probabilidad *a priori*. Tanto la estructura como los parámetros numéricos de una RB pueden ser determinados por un experto. Sin embargo, también pueden aprenderse a partir de datos, ya que la estructura de una RB es una representación de independencias en los datos, y los números son una representación de las distribuciones de probabilidad conjunta, estos pueden ser inferidos a partir de los datos. Otra alternativa que existe, es que tanto la estructura como las probabilidades sean una combinación del conocimiento experto con mediciones y datos de frecuencia objetiva.

El enfoque bayesiano en estas redes, permite que los datos de la distribución de probabilidad sean actualizados a la luz de nueva evidencia usando el teorema de Bayes [7]. La inferencia bayesiana permite calcular el impacto de valores observados en un subconjunto de variables del modelo sobre los valores de las variables remanentes. la estructura del modelo, es decir, una declaración explícita de independencias en el dominio, ayuda a desarrollar algoritmos de actualización eficientes. La actualización en redes bayesianas es computacionalmente compleja. En el peor caso, los algorit-

mos de actualización de creencias son del tipo NP-duro [21]. Sin embargo, existen varios algoritmos eficientes, que hacen que grafos con miles de variables sean tratables. Pearl [87] desarrolló un esquema basado en el paso de mensajes para actualizar la distribución de probabilidad de cada nodo en respuesta a observaciones de una o más variables. Lauritzen y Spiegelhalter [61], propusieron un algoritmo eficiente que primero transforma una RB en una estructura de árbol, donde a cada nodo del árbol, corresponde un subconjunto de variables del grafo original. El algoritmo explota propiedades matemáticas del árbol para realizar la inferencia probabilística. Asimismo, se han propuesto varios algoritmos de aproximación basados en un proceso de muestreo estocástico, algunos de los más conocidos, son el algoritmo de muestreo lógico probabilista de Henrion [40], y el algoritmo de muestreo de máxima verosimilitud de Shachter [102].

Aunque las RBs son un enfoque gráfico muy utilizado en aplicaciones de razonamiento bajo incertidumbre, su uso es hacia el análisis de procesos estáticos. Para describir sistemas dinámicos, donde se observa una variación temporal en las variables que los describen, se aplican las redes bayesianas dinámicas.

#### 3.3.2. Redes bayesianas dinámicas

Las redes Bayesianas dinámicas (RBDs) [26], son modelos gráficos muy populares por permitir una eficiente inferencia de creencias. La clave para emplear estos modelos en aproximar soluciones a problemas POMDP, consiste en explotar la independencia condicional, que permite el razonamiento a nivel variables en lugar del nivel estado, lo que permite a su vez disminuir la dimensionalidad del espacio de estados. Una RBD es un grafo acíclico que codifica funciones de transición y observación en cada período de tiempo. La Figura 3.3, ilustra a una RBD mostrando dos etapas de tiempo  $t$  y  $t + 1$ , la cual representa a un sencillo POMDP de tres variables de estado ( $W, X, Y$ ) y una variable de observación ( $O$ ). En esta figura, los arcos entre las variables indican la dependencia condicional entre ellas.

Las funciones de transición y observación se representan numéricamente por tablas de probabilidad condicional (TPC), las cuales, indican la distribución condicional  $Pr(v|p_v^1, p_v^2, \dots, p_v^n)$  de cada variable  $v$  dados sus padres  $p_v^1, p_v^2, \dots, p_v^n$ . La Figura 3.3, muestra una TPC para  $Pr(W|W, Y)$ <sup>1</sup>. La independencia condicional puede considerarse para calcular el siguiente estado de creencia  $b_{t+1}$  a partir del estado de creencia actual  $b_t$  (dada alguna acción  $a$ , u observación  $o$ ). Los estados de creencia  $b_t$  y  $b_{t+1}$ , corresponden en una RBD a las distribuciones conjuntas  $Pr(W, X, Y)$  y  $Pr(W', X', Y)$  respectivamente. La actualización de los estados de creencia en un POMDP usando el paradigma de RBDs responden a la siguiente interrogante:  $¿Pr(W', X', Y|O = o)?$ . La respuesta se contesta a través de aplicar una variedad de algoritmos. Un método común es construir una estructura secundaria conocida como árbol de cliques [46], y aplicar un proceso de inferencia de creencia a la misma. El árbol de cliques, es una representación factorizada compacta de la distribución conjunta  $Pr(W, X, Y, W', X', Y, O)$  que explota la independencia entre variables. Aunque este puede ser un método común para calcular la inferencia en RBDs, en este caso el cálculo depende del tamaño del clique, el cual puede incrementarse al correlacionarse las variables en el tiempo. Esto sugiere que la actualización de estados de creencia a través de RBDs aplicando este mecanismo de inferencia, debe mantener un número pequeño de variables dependientes conforme pasa el tiempo, esto pocas veces ocurre en la práctica. Por lo tanto, es necesario buscar métodos más eficientes que aproximen inferencias a las RBDs, y poderlos aplicar a solucionar problemas POMDPs. Uno de estos enfoques son los esquemas de proyección

---

<sup>1</sup>Se asume que las variables son binarias.

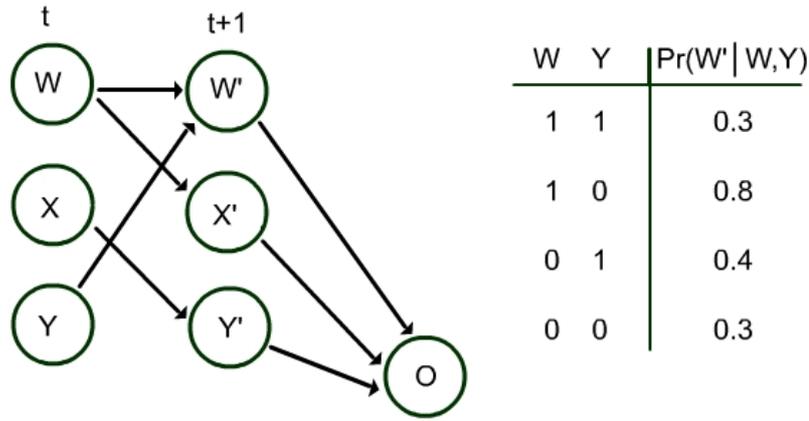


Figura 3.3: Red bayesiana dinámica analizada en dos etapas de tiempo  $t$  y  $t + 1$ .

propuestos por Boyen y Koller [15]. Otras propuestas para mejorar los algoritmos de inferencia clásicos son realizadas por Shachter y Peot [102], quienes utilizan técnicas de agrupamiento de árboles para llevar a cabo el proceso de inferencia en RBDs.

### 3.4. Redes de decisión

Las redes de decisión (RDs) o diagramas de influencia [45], son una extensión de las redes bayesianas que incorporan nodos de decisión y utilidad, con la capacidad de representar problemas de decisión. El objetivo de las RDs es la elección de alternativas bajo un enfoque de máxima utilidad esperada. De manera similar a las RBs, las RDs son útiles para representar la estructura del dominio, es decir, la estructura del problema de decisión. Una red de decisión se describe por un grafo acíclico dirigido  $N$ , que contiene nodos representando las variables de un problema de decisión,  $V = X \cup D \cup U$ . Cada variable tiene su propio dominio de valores,  $dom(v)$ . El conjunto de padres de un nodo  $v_i$  es denotado como  $\pi_{v_i}$ . Estas variables son de tres tipos, tal como se ilustran en la Figura 3.4:

- Nodos *aleatorios*,  $x_i \in X$ , representan variables aleatorias, las cuales tienen asociada una tabla de probabilidad condicional (ver Figura 3.3), representando la distribución  $P(x_i|\pi_{x_i})$ .
- Nodos de *decisión*,  $d_i \in D$ , representan las decisiones que se van a realizar. Es común utilizar *reglas de decisión*  $\delta_i$  para representar el mapeo de cada permutación de los padres a exactamente una decisión,  $\delta_i(\pi d_i) \in dom(d_i)$ .
- Nodos de *utilidad*, denotados por  $u_i \in U$ , representan funciones que mapean cada permutación de sus padres a exactamente un valor de utilidad  $val_{u_i}(\pi_{u_i}) \in dom(u_i)$ . Los nodos de utilidad no tienen nodos sucesores (nodos hijo).

Una regla de decisión óptima  $\delta_i^*$ , es aquella que maximiza  $E_{\delta_i} [val_{u_i}(\pi_{u_i})]$ , el valor esperado de los nodos de utilidad que afecta. El objetivo al realizar el análisis de decisiones, es encontrar una *política óptima*  $\Delta$ , la cual es el conjunto de todas las reglas de decisión óptimas  $\Delta = \{\delta_1^*, \dots, \delta_k^*\}$ , una para cada nodo de utilidad. Las RDs simplifican el modelado, permitiendo el análisis sobre nodos específicos que representan distribuciones de probabilidad completas y relaciones con otras variables.

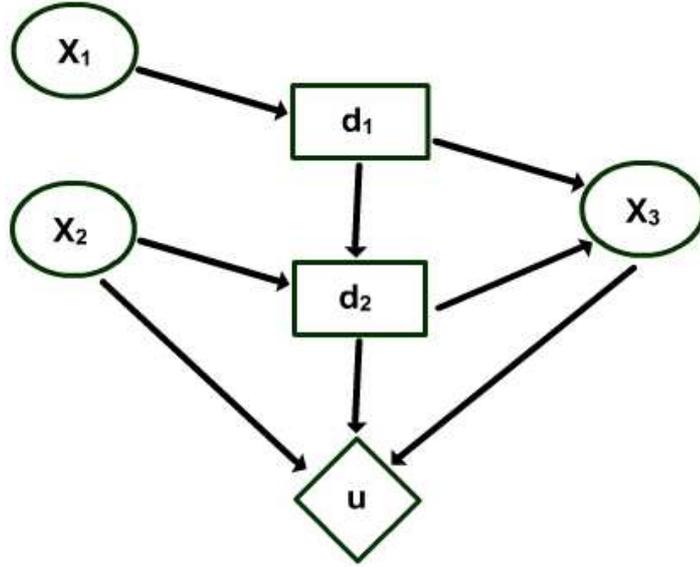


Figura 3.4: Estructura básica de una red de decisión.

### 3.4.1. Evaluación de la red de decisión

Normalmente los algoritmos utilizados para evaluar redes bayesianas también se aplican para la evaluación de las redes de decisión (RDs). Este enfoque, fue inicialmente propuesto por Cooper [22], quien mostró como reducir las RDs a redes bayesianas. Posteriormente Shachter y Peot [102] mostraron una mejora al algoritmo de Cooper el cual resulta más eficiente. En ese mismo enfoque, Zhang [126] introdujo una versión modificada al algoritmo que reduce sustancialmente el número de nodos considerados en cada parte de la evaluación. Xiang [120] propuso un algoritmo que asegura ser tan eficiente como el de Zhang, pero más simple. Enseguida se ofrece una breve descripción de algunos de estos algoritmos.

**El algoritmo de reducción de Cooper** [22] convierte un problema de RD, a un problema de RB, de la siguiente forma. Se debe asegurar que todos los nodos (*decisión*, *utilidad* y *aleatorios*) en una RD tengan distribuciones de probabilidad apropiadas asociadas a ellos, para realizar la inferencia como en una RB. Los nodos de decisión son convertidos a nodos aleatorios para obtener una distribución de probabilidad, aplicando la siguiente expresión:

$$\forall \alpha_{d_i} \in \text{dom}(d_i), P(\alpha_{d_i} | \pi_{d_i}) = \frac{1}{|\text{dom}(d_i)|}$$

Asimismo, se necesita asignar una probabilidad a los nodos de utilidad para realizar su transformación. Cooper asignó la probabilidad a los nodos de utilidad dados sus padres en la RB de la siguiente manera:

$$P(u = 1 | \pi_u) = \frac{\text{val}_u(\pi_u)}{\max_{\pi_u} \text{val}_u(\pi_u)}$$

$$P(u = 0 | \pi_u) = 1 - \frac{\text{val}_u(\pi_u)}{\max_{\pi_u} \text{val}_u(\pi_u)}$$

Esta es una probabilidad proporcional al valor de la función de utilidad en una RD con los mismos padres. Los nodos aleatorios permanecen sin cambios. Una vez realizada la transformación, el problema de encontrar una decisión óptima en la RD, se reduce al siguiente problema en una red bayesiana:

$$E_{\delta_i}[val_u(\pi_u)] = P(u = 1|\pi_u)$$

donde  $E_{\delta_i}[val_u(\pi_u)]$  representa el valor esperado de los nodos de utilidad dados sus padres.

El método sugerido por Cooper se reduce a obtener una solución maximizando  $\delta_i$  en cada permutación de  $\pi_u$ . Este procedimiento puede requerir un número exponencial de pasos de inferencia. Sin embargo, trabajos posteriores realizaron mejoras a este algoritmo, haciéndolo más eficiente. En este trabajo se aplica el algoritmo de Cooper para convertir la red de decisión a una red bayesiana y posteriormente se aplica el algoritmo exacto de inferencia bayesiana *Junction tree* [46].

**Método propuesto por Shachter y Peot** [102]. Este método ofrece una mejora al trabajo de Cooper y sólo aplica para redes de decisión con un nodo de valor. El procedimiento para convertir una red de decisión a una red bayesiana bajo este método es el siguiente:

- Todos los nodos aleatorios en la red de decisión permanecen sin cambio.
- Transformar el nodo de decisión  $d_1$  en un nodo aleatorio. Este nodo debe tener el mismo espacio  $D_{d_1}$  y el mismo conjunto de nodos padres  $\pi_{d_1}$  que el nodo de decisión. La distribución uniforme asociada a este nodo está definida por

$$P(d_1|\pi_{d_1}) = const$$

donde  $const$  es una constante de normalización tal que  $\sum_i P(d_{1,i}|\pi_{d_1}) = 1$  para cada configuración de  $\pi_{d_1}$ .

- Convertir el nodo de valor  $u$  en un nodo binario  $v$  con un espacio  $\{0, 1\}$ , con los mismos padres  $\pi_u = \pi_v$ , y una distribución definida por

$$P(u = 1|\pi_u) = v(\pi_v)$$

Una vez convertida la red de decisión a una red bayesiana, los autores demuestran que el cálculo de la probabilidad posterior en la red bayesiana corresponde a evaluar la utilidad esperada en la red de decisión.

#### 3.4.2. MDP de horizonte finito

Los procesos de decisión de Markov (MDPs) con horizonte finito pueden verse como un caso especial de redes de decisión (RDs), las cuales son un esquema más general de modelos gráficos, utilizados para representar problemas de decisión. Aunque la definición tradicional de una RD [45] especifica solamente un nodo de valor o de utilidad, algunos trabajos han aplicado múltiples nodos de valor, lo cual se realiza simplemente factorizando la función de utilidad [61, 102]. La Figura 3.5

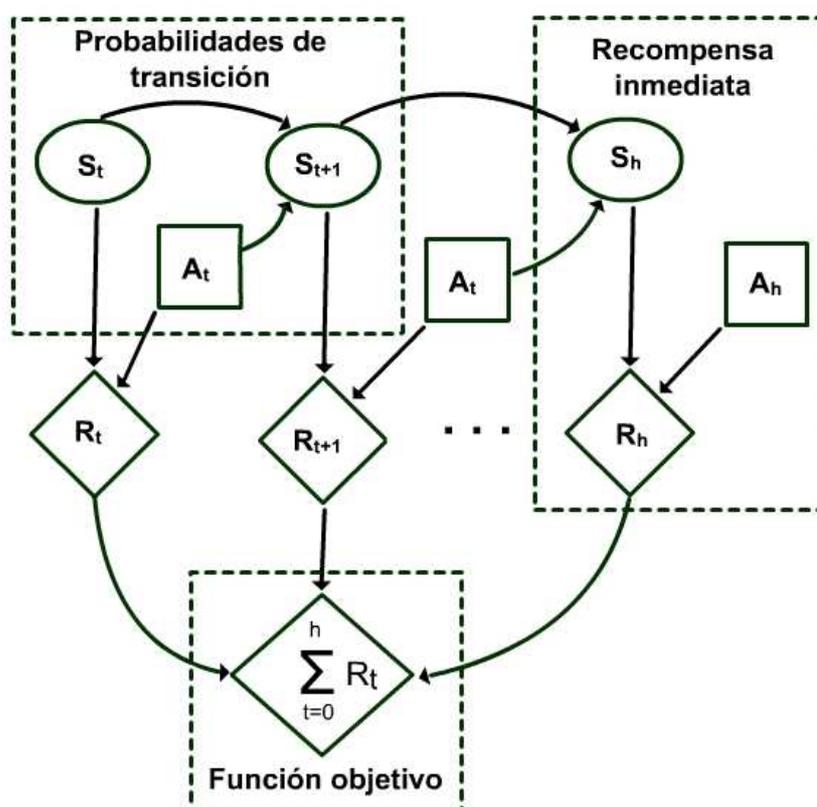


Figura 3.5: Red de decisión representando a un MDP de horizonte finito, los arcos informativos no son mostrados para claridad de la imagen. Se observan los componentes de un MDP: conjunto de estados ( $S_t, S_{t+1}, \dots, S_h$ ), conjunto de acciones ( $A_t, A_{t+1}, \dots, A_h$ ) probabilidades de transición entre estados ( $S_t, S_{t+1}$ ), recompensa inmediata  $R$  y la función objetivo (en este caso es la función de valor obtenida por la suma de las recompensas).

muestra una red de decisión representando a un MDP de horizonte finito, donde todos los estados  $s \in S$  se han mapeado a nodos aleatorios, todas las acciones  $a \in A$ , a nodos de decisión, y todas las  $R$ , a nodos de valor indicando la recompensa inmediata de tomar la acción  $a$  en el estado  $s$  y en el tiempo  $t$ . El nodo de utilidad, mostrado en la parte inferior de la figura, mantiene la suma de todas las recompensas inmediatas (Ec. 3.1).

Aunque en la Figura 3.5 se muestra la representación de un MDP con horizonte finito a través de una red de decisión, éstas también son capaces de representar problemas POMDPs de horizonte finito. Sin embargo, en el proceso de analizar las etapas futuras con el fin de anticipar la toma de decisiones se vuelve complicado para una red de decisión, ya que implica el análisis de una secuencia de estructuras con posibles cambios en las distribuciones marginales entre una etapa y otra. Por lo tanto, es necesario utilizar un mecanismo de cálculo más eficiente: las redes de decisión dinámicas (RDDs).

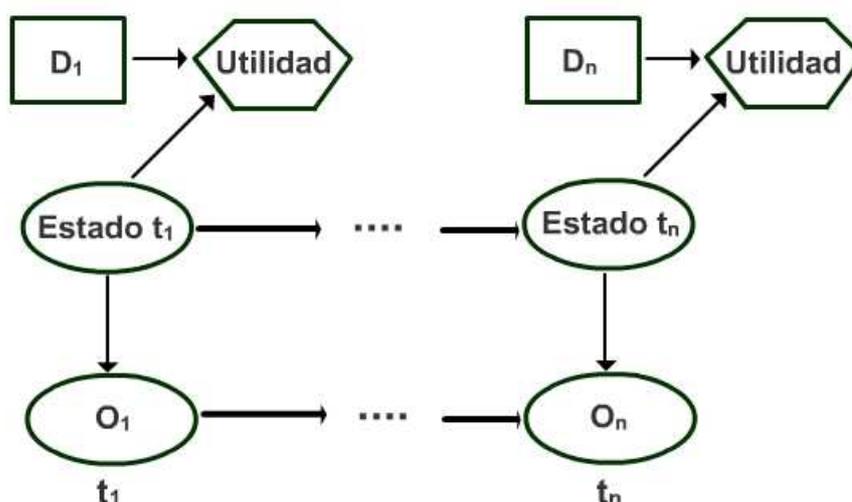


Figura 3.6: Estructura general de una red de decisión dinámica, donde el problema de decisión consta de  $n$  pasos.

### 3.5. Redes de decisión dinámicas

Las redes de decisión dinámica (RDDs) [101], permiten aproximar soluciones a problemas POMDPs de horizonte finito, a través de representar tanto acciones probabilísticas como estados parcialmente observables. Una red de decisión dinámica (RDD), es similar a una red bayesiana dinámica (RBD), la diferencia es que posee además de los nodos *aleatorios*, nodos de *decisión* y de *valor*. Las RDDs modelan problemas de decisión secuencial en situaciones donde las decisiones, variables, o preferencias cambian con el tiempo. Al igual que las RBDs, existen algoritmos simples que permiten representar la evolución de una RDD mientras mantiene en la memoria al menos dos etapas a la vez. Los algoritmos de evaluación para las RDDs, básicamente son los mismos que los utilizados en las RDs [102, 120, 126]. El problema de decisión, consiste en calcular el valor de  $D_t$  que maximice la utilidad esperada a través de analizar una secuencia de estados futuros<sup>2</sup> (ver Figura reffig:capi306).

En el peor de los escenarios, la RDD calcula la utilidad esperada de las secuencias de decisión fijando los nodos de decisión y aplicando inferencia probabilística para obtener el estado final. Hay que tener presente el hecho de que al momento de tomar la decisión, desconocemos la información de la que dispondremos en los estados futuros (mediante las observaciones). La utilidad esperada en cada ciclo de decisión, es por tanto, la suma ponderada de todas las utilidades calculadas utilizando todas las posibles secuencias de decisión. La utilidad final, se obtiene aplicando las Ecs. 3.1 ó 3.2 (definidas en la Sección 3.1) para los procesos de decisión de Markov de estado finito, las cuales también son aplicables a los procesos de decisión de Markov parcialmente observables. Es decir, la RDD ofrece soluciones aproximadas a problemas de decisión de Markov parcialmente observables, en los que el grado de aproximación dependerá del número de etapas temporales analizadas. Existen otras técnicas de aproximación, tal como el uso de variables de estado menos detalladas para determinar estados futuros; el uso de una búsqueda heurística glotona a través de las secuencias del espacio de decisión; el suponer los valores *más probables* de futuras secuencias de percepción en vez de considerar todos los valores posibles.

<sup>2</sup>Generalmente, la utilidad final se calcula sumando las recompensas esperadas en cada una de las etapas  $R_t + R_{t+1} \dots R_h$

El empleo de las RDDs con el fin de aproximar soluciones a problemas POMDP de horizonte finito ofrece las siguientes ventajas:

- Acelera la construcción de políticas óptimas.
- Puede servir para desarrollar métodos de aproximación de políticas en POMDPs.

Asimismo, también posee algunos inconvenientes, tal como asociar la historia de acciones y observaciones en cada etapa de decisión, así como el empleo de una búsqueda ineficiente.

## 3.6. Resumen del capítulo

Los procesos de decisión de Markov han sido la técnica preferida para modelar tareas de planeación y aprendizaje en dominios estocásticos. Sin embargo, esta técnica considera que los estados del mundo son completamente observables, lo cual no se cumple en la mayoría de los ambientes reales. Los procesos de decisión de Markov parcialmente observables manejan esta limitante al considerar estados parcialmente observables. Sin embargo, encontrar la solución exacta a un problema POMDP de horizonte finito se ha demostrado que es un problema *NP-duro* [21], y para el caso de horizonte infinito el problema es aún peor. Estos problemas han propiciado la búsqueda de métodos de solución aproximados. Los métodos estructurales (RBs, RBDs, RDs, RDDs), se han propuesto de manera reciente para permitir el uso de técnicas clásicas de solución sin necesidad de una completa enumeración del espacio de estados. De estas alternativas, las redes de decisión dinámicas han surgido como una opción para modelar de manera eficiente problemas de decisión dinámica. Estas redes han proporcionado resultados satisfactorios en diferentes aplicaciones, tales como: análisis de tráfico [48], sistemas tutores inteligentes [18, 80], planeación [27], decisiones clínicas [65] y sistemas militares [57]. El empleo de las RDDs para tomar decisiones dinámicas basadas en el comportamiento humano a través de cámaras de vídeo es un tópico que aún no se ha explorado. Asimismo, es necesario definir una manera eficiente para determinar el número de etapas temporales consideradas, una forma puede ser utilizar aspectos de convergencia en los valores de utilidad obtenidos en etapas temporales sucesivas.

# Capítulo 4

## Reconocimiento de gestos utilizando contexto

En este capítulo se van a describir las fases empleadas durante el proceso de reconocimiento de gestos al interactuar las manos de una persona con objetos del entorno (bloque I del diagrama mostrado en la Figura 1.1). Vamos a iniciar la Sección 4.1, describiendo la información contextual que se va a utilizar en este trabajo. En la Sección 4.2 se describe el proceso de segmentación para detectar y aislar a una persona en una secuencia de imágenes, enseguida se repite el proceso relacionado con los objetos. En la Sección 4.3 se va a detallar la fase de seguimiento relacionada con las manos de una persona y con objetos. La elección y extracción de características utilizadas se describe en la Sección 4.4. En la Sección 4.5 se explica la discretización de los datos correspondientes a las características que se van a utilizar. El uso de los modelos ocultos de Markov como técnica de representación de gestos se describe en la Sección 4.6. La descripción del proceso de aprendizaje se realiza en la Sección 4.7, Finalmente, en la Sección 4.8 se evalúa el sistema de reconocimiento de gestos mostrando dos opciones: (a) sin usar contexto, y (b) utilizando contexto.

### 4.1. Información contextual utilizada

En este capítulo se va a describir el bloque I del diagrama mostrado en la Figura 1.1. Este bloque se relaciona con el proceso de reconocimiento de gestos a través de los modelos ocultos de Markov [96]. Se va a iniciar con la fase correspondiente a la detección y seguimiento del objeto de interés (mano de una persona), antes de iniciar con esta fase se dará una explicación de lo que en este trabajo se considera información de contexto.

En este trabajo se postula la siguiente hipótesis: *El uso de información de contexto mejora el proceso del reconocimiento automático de los gestos realizados por una persona.*

De acuerdo con el diccionario de la Real Academia de la Lengua Española, la palabra contexto tiene varias definiciones <sup>1</sup>. En el ámbito de visión computacional, el *contexto* se relaciona generalmente con información *a priori* enfocada a mejorar o apoyar los procesos de detección, seguimiento, reconocimiento, o interpretación de la interacción humana.

---

<sup>1</sup>a) *Contexto*, es un entorno lingüístico del cual depende el sentido y el valor de una palabra, frase o fragmento considerados, b) *Entorno físico o de situación*, ya sea político, histórico, cultural o de cualquier otra índole, en el cual se considera un hecho

Por lo tanto, en esta tesis el contexto lo forma la siguiente información:

- La distancia relativa entre el centroide de la mano y el centroide de los objetos.
- Los objetos de interés presentes en el escenario y los cuales pueden ser manipulados por una persona.

Las etapas que forman bloque I y cuya finalidad es reconocer los gestos que realiza una persona al interactuar con objetos de su entorno se basan en un enfoque *bottom-up* y son descritas a continuación.

## 4.2. Detección y seguimiento de la mano de una persona

La detección automática de objetos de interés en imágenes ha sido motivo de investigación durante décadas. Gran parte de los trabajos realizados se centran en reconocer partes específicas de la persona tales como la cara o manos [124]. La confiabilidad de los resultados obtenidos en esta fase es determinante en el rendimiento de sistemas de reconocimiento y seguimiento de partes de una persona. Los diversos métodos de detección de partes de una persona pueden clasificarse en dos grandes grupos:

- a) métodos tradicionales basados en detección de características (*featured-based*), que utilizan datos explícitos como modelos colorimétricos o geométricos de partes de una persona y,
- b) métodos recientes que se basan en métodos de reconocimiento de patrones (*image-based*), los cuales obtienen información de manera implícita mediante el aprendizaje a partir de ejemplos o patrones.

Los métodos basados en detección de características utilizan aspectos de visión de bajo nivel como son los bordes, los niveles de gris, el color y el movimiento. En un espacio cromático, el color de la piel humana (sea cual sea el grupo étnico al que pertenezca) puede ser modelado mediante una distribución gaussiana sencilla. Estos métodos son apropiados para el procesamiento de una secuencia de imágenes en tiempo real cuando el color y el movimiento son posibles. Para imágenes estáticas representadas en niveles de gris los métodos basados en reconocimiento de patrones son más adecuados.

El sistema de visión que se utiliza en este trabajo emplea un método que detecta partes de una persona (principalmente manos) mediante el aprendizaje del color de la piel. El algoritmo empleado se basa en un clasificador bayesiano que distingue los colores naturales asociados a partes de una persona (manos) de los que no lo son. El proceso de detección y seguimiento utilizado en este trabajo se ilustra en la Figura 4.1. A continuación se describe cada bloque.

### 4.2.1. Modelo de color utilizado

El proceso que se aplica en este trabajo para segmentar partes de una persona se basa en dos características de bajo nivel: (i) *color* y, (ii) *movimiento*. El color es una característica distintiva de

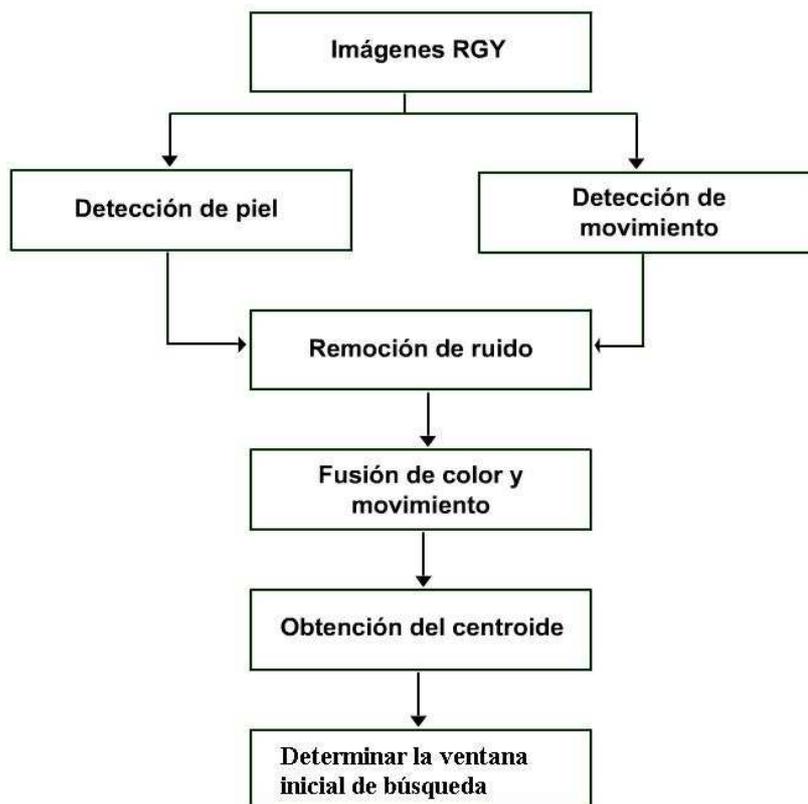


Figura 4.1: Proceso de detección de partes del cuerpo de una persona en base al color de piel

los objetos, el cual es rápido de procesar e invariante a escalado, rotación y traslación [107]. Estas propiedades son importantes para un sistema que realiza el seguimiento del rostro y/o manos de una persona en tiempo real. Existen varios trabajos donde se han mostrado resultados satisfactorios de algoritmos basados en el color de la piel con el fin de realizar la detección y seguimiento de una persona [31, 76, 125]. La determinación de los modelos de color de piel ha sido estudiado en algunos trabajos [63, 124], sin embargo, no se ha llegado a pruebas concluyentes de un modelo único y representativo de la piel humana. En algunos trabajos se aplica el espacio de color *RGB*, donde la tripleta  $[R,G,B]$  representa no solo el color sino también la brillantez. Una forma común de separar los colores cromáticos o colores puros  $(r, g, b)$  de la brillantez, es la aplicación de un proceso de normalización [35], utilizando la siguiente expresión,

$$r = R/(R + G + B), g = G/(R + G + B), b = B/(R + G + B) \quad (4.1)$$

donde se define un mapeo de  $\mathcal{R}^3$  a  $\mathcal{R}^2$ , el color  $b$  es redundante después de la normalización debido a que  $r + g + b = 1$ . Yang y otros [124] demostraron que la distribución de color de la piel humana tiende a agruparse en una pequeña región en el espacio  $(r, g)$ . Aunque los colores de piel de diferentes etnias varíen en un amplio rango, se cree que estas variaciones son causadas principalmente por la brillantez o intensidad. Lu y otros [63] basados en los resultados de Yang [124], realizaron un estudio de las propiedades de varios filtros aplicados al color de piel, los cuales son usados en la detección de caras y proponen un nuevo modelo basado en una tabla de búsqueda utilizando el componente  $H$  del modelo *HSV*, similar al enfoque propuesto por Bradsky y otros [16]. Otros trabajos que utilizan el modelo de color *HSV*, demuestran que este enfoque realiza mejor la clasificación de

píxeles de piel que los modelos basados en *RGB* [16,91].

En esta tesis se aplica un enfoque novedoso para la detección y seguimiento de piel humana, basada en el uso de características de color y movimiento así como en el empleo de un nuevo modelo de color. La técnica propuesta utiliza un modelo de color de piel basado en histogramas de color y se ha desarrollado con base en un gran conjunto de datos de entrenamiento de color de *piel* y de *no piel* [52]. Un modelo de color de piel humana se caracteriza por un algoritmo de clasificación y un espacio de color utilizado para representar el color del píxel. En este trabajo se utiliza un clasificador probabilístico basado en una modificación de la regla de Bayes propuesta por Jones y Rehg [52]. El espacio de color que utilizado en este trabajo es el *RGY*, y es una aportación de Martínez y Sucar [67]. En la Tabla 4.1, mostramos los resultados al comparar el espacio de color utilizado con otros (*RGB*, *Y<sub>c</sub>C<sub>b</sub>*, *HSV*) al evaluar imágenes de prueba, se observa en estos resultados que el modelo *RGY* obtiene un mejor porcentaje de clasificación. Para obtener estos resultados, los modelos fueron entrenados utilizando una base de datos conteniendo 3,354,974 píxeles de piel y 3,459,358 píxeles de no piel. En la Figura 4.2 se muestran imágenes donde se ilustra la aplicación del espacio de color *RGY* en la segmentación de píxeles de piel y su comparación con otros espacios de color.

Con el fin de simplificar el procesamiento al manejar el espacio de color seleccionado, el rango de valores para cada píxel (0-255) en cada canal de color *RGY*, se divide en segmentos (*bins*) de tamaño 32. Por lo tanto, en vez de considerar el manejo de una matriz *3D* con un tamaño de  $256 \times 256 \times 256$ , se considera una matriz *3D* de tamaño  $32 \times 32 \times 32$ . Asimismo, con el fin de optimizar la segmentación, se crea un mapa de probabilidad de piel, obtenido a partir de bases de datos con valores de imágenes de piel y no piel y se calcula a partir de esta información todos los posibles valores que forman la tripleta *RGY*, y formar la matriz de tamaño  $32 \times 32 \times 32$  mencionada con anterioridad. Posteriormente, determinamos la probabilidad de pertenencia a la clase *piel* y *no piel* que cada valor de píxel contenido en cada tripleta, aplicamos para ello una variación de la regla de Bayes [52]. La tabla de probabilidad correspondiente a valores de piel se va a utilizar en la etapa de seguimiento.

### 4.2.2. Segmentación basada en movimiento

Una de las desventajas del uso del color como técnica de segmentación es su susceptibilidad a la variación luminosa, lo cual hace a esta técnica poco adecuada para aplicarse en ambientes reales. Aunque trabajos recientes han desarrollado algoritmos basados en color confiables para la detección y seguimiento de objetos [16, 30, 63, 91, 124], el uso demandante que hacen de técnicas y recursos los hacen poco favorables para ser utilizados en aplicaciones de tiempo real. Por otro lado, el uso de información de movimiento como característica para segmentar objetos de interés en una imagen es un método confiable a variaciones luminosas (característica de los ambientes reales), pero resulta

Tabla 4.1: Clasificador bayesiano usado para determinar la clase piel en diferentes espacios de color.

Espacio de color	Porcentaje de acierto
RGB	94.42
HSV	93.50
$Y_{c}C_{b}$	91.46
RGY	97.20

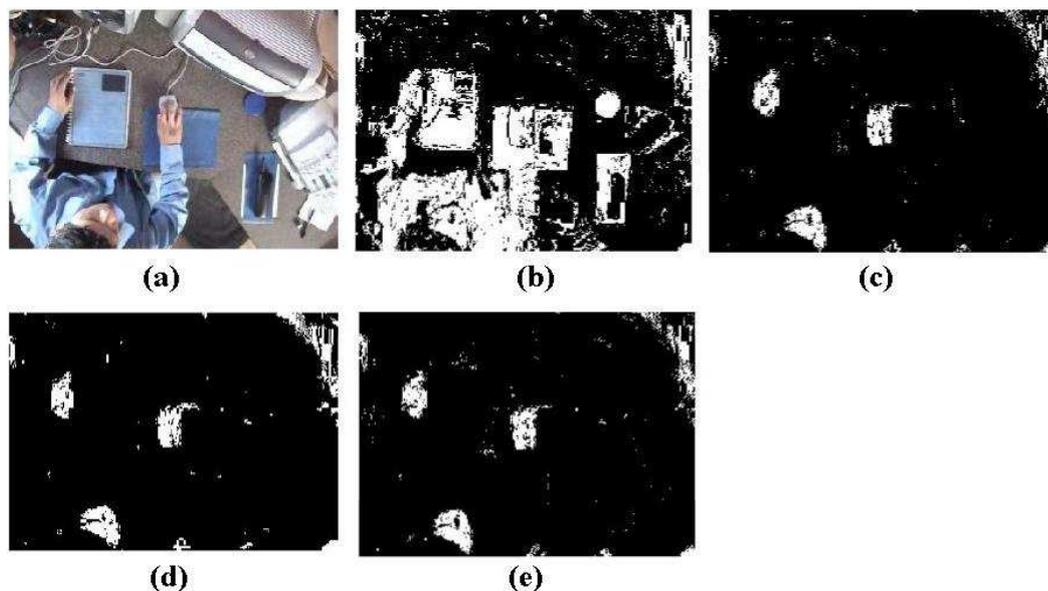


Figura 4.2: Serie de imágenes mostrando diferentes modelos de color utilizados en la detección de regiones de piel humana: (a) imagen original, (b)  $HSV$ , (c)  $RGB$ , (d)  $Y_{CrCb}$ , (e)  $RGY$ .

computacionalmente costosa, sobretodo si se utilizan aspectos como el flujo óptico [37]. Sin embargo, también es posible el uso de técnicas simples como la sustracción de imágenes para determinar regiones en movimiento [37]. Integrar aspectos de color y movimiento crea sistemas robustos que reúne lo mejor de ambos enfoques. En este trabajo, se aplica la sustracción de imágenes para determinar regiones en movimiento, pero, a diferencia de otros enfoques que utilizan una imagen de referencia determinada previamente, en esta tesis tal imagen se obtiene durante la ejecución del modelo (en los primeros cuadros de la secuencia de imágenes). Asimismo, la intención es crear un modelo computacional que pueda ser aplicado en tiempo real, por lo tanto se busca que la fase de detección sea simple y confiable. Por lo tanto, a diferencia de otros enfoques que utilizan información de color y movimiento durante todo su proceso (detección, seguimiento y reconocimiento de gestos [31, 125]), en este trabajo la combinación de color y movimiento solamente se aplica durante la detección del objeto de interés (mano humana), posteriormente se confía en la información de color. Se puede establecer que una vez determinada la parte de interés, la iluminación se puede considerar con poca variación durante el tiempo de aplicación del sistema (ambientes que no son de uso prolongado: video conferencias, apoyo para completar tareas).

**Detección de movimiento.** El método utilizado para segmentar con base en el movimiento es una variación del trabajo de Jabri [51], y se basa en la diferencia entre cuadros de imágenes consecutivos. Aplicamos la sustracción de imágenes para cada canal en el modelo de color RGY, resultando tres imágenes diferentes:

$$R_{Diff} = R_{anterior} - R_{actual}$$

$$G_{Diff} = G_{anterior} - G_{actual}$$

$$Y_{Diff} = Y_{anterior} - Y_{actual}$$

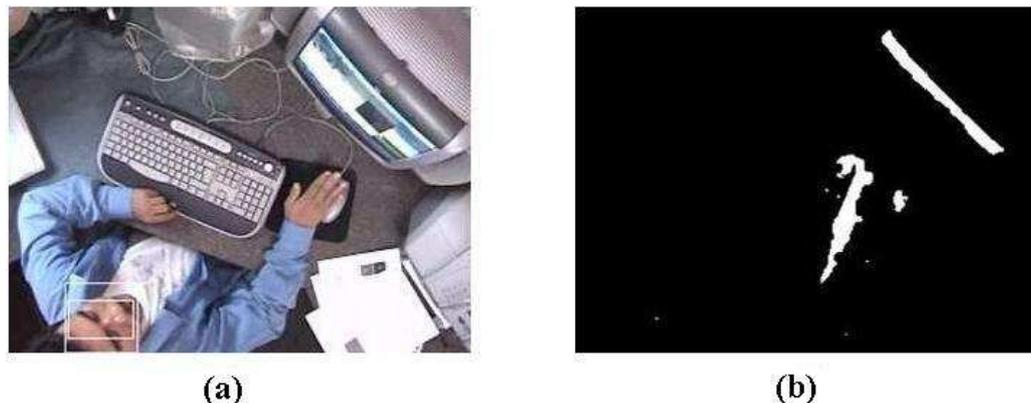


Figura 4.3: Segmentación utilizando movimiento: Imagen izquierda muestra la imagen original. La imagen derecha muestra las regiones en movimiento.

A estas imágenes se les aplica un proceso de normalización para cada canal usando dos umbrales ( $M_o$  y  $m_o$ ) cuyos valores son elegidos de forma experimental. Los valores de umbrales utilizados en este trabajo son:  $m_o = 20$  y  $M_o = 50$ . Asimismo, para considerar todo el espacio de color, se aplica la siguiente regla: Si el valor de la diferencia es menor que  $m_o$  entonces se fija a 0, si es mayor que  $M_o$  entonces se fija a 255. Para valores intermedios de la diferencia, el valor es escalado linealmente por:

$$C_x = ((D - m_o) / (M_o - m_o)) * 255 \quad (4.2)$$

donde  $D$  es el valor de la diferencia.

Finalmente se selecciona la imagen con el mayor de los tres canales.

$$D_x = MAX(R_{Diff}, G_{Diff}, Y_{Diff}) \quad (4.3)$$

En este momento se tiene una imagen en escala de grises a la cual se aplica un proceso de filtrado utilizando la media de los píxeles vecinos con el fin de eliminar píxeles aislados (ruido). Posteriormente, se genera una imagen binaria cuyo umbral adaptado a las condiciones ambientales actuales se obtiene aplicando el algoritmo de Otsu [83]. Este mecanismo de obtener la imagen binaria adaptada a las condiciones actuales es más sencillo que el utilizado por Jabri, el cual se basa en un análisis estadístico más detallado así como la descripción de una secuencia de imágenes con el fin de obtener una representación confiable del fondo de un escenario. En la Figura 4.3, se ilustra el resultado del proceso de segmentación descrito.

### 4.2.3. Combinando color y movimiento

El proceso para detectar regiones de piel en movimiento se ilustra en la Figura 4.4. En la imagen (b) se observan las regiones en movimiento (en este caso: brazo derecho de la persona y el movimiento causado por la pantalla de la computadora). Se trata de determinar solamente las regiones

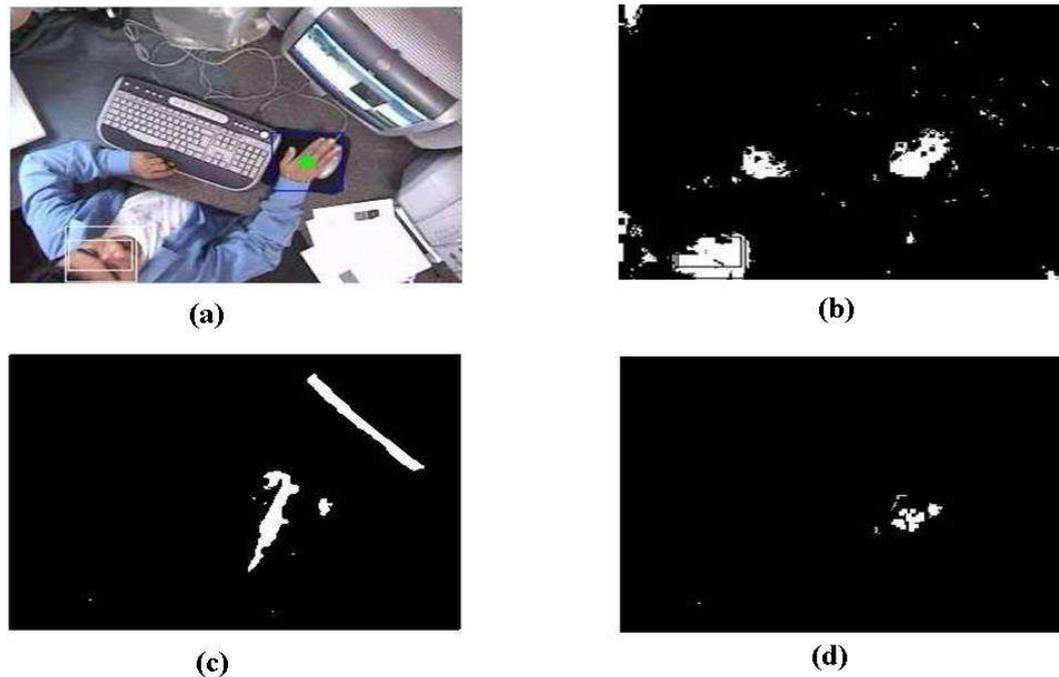


Figura 4.4: Integración de información de color y movimiento. La imagen (a) muestra la imagen original. La imagen (b) ilustra el resultado de la segmentación con base en información de color. La imagen (c) muestra la imagen segmentada con base en movimiento. Finalmente, (d) muestra la imagen resultante de combinar las dos anteriores.

en movimiento que pertenezcan a la clase piel. Por lo tanto, es necesario realizar un procedimiento similar al usado en el trabajo de Yoon y otros [125], es decir, aplicar una operación lógica AND entre la imagen que contiene los píxeles segmentados utilizando información del color de piel (imagen (b) de la Figura 4.4), y la imagen que contiene píxeles segmentados utilizando información de movimiento (imagen (c) de la Figura 4.4). La imagen resultante es una imagen binaria que contiene píxeles etiquetados con las regiones de piel en movimiento (imagen (d) de la Figura 4.4).

Una vez determinadas las regiones de piel en movimiento, se procede a ubicar la región de interés <sup>2</sup>, para ello aplicamos las siguientes heurísticas:

- La mano de una persona es la mayor región de piel que aparece en una secuencia de imágenes.
- La mano (izquierda o derecha) de una persona es la mayor región de piel capaz de generar un movimiento significativo.

Para facilitar este proceso, la persona debe mover primero una de las manos al iniciar la operación del sistema con el fin de ubicar la región de interés en la secuencia de imágenes (aunque no es restrictivo se recomienda utilizar una camisa de mangas largas y con un color distinto al de piel humana). El paso siguiente consiste en determinar la ventana inicial de búsqueda la cuál debe encerrar al objeto de interés, para este fin se aplican momentos de orden 0 y 1 los que a la vez ubican el centroide de la ventana. Una vez encerrada la región de interés en una ventana y localizado su

---

<sup>2</sup>Inicialmente se realizaron pruebas detectando las partes de piel visibles en una persona (rostro y manos), con fin de determinar la operación del modelo diseñado con respecto al proceso de segmentación. Actualmente, la única parte del cuerpo que se utiliza es la mano de una persona.

centroide, se realiza el seguimiento de la misma aplicando para ello el algoritmo de *CamShift* [16]. Sin embargo, este algoritmo ajusta la nueva ventana incorporando la totalidad de región de piel que detecta en la imagen. En uno de los escenarios utilizados en este trabajo, es deseable que el algoritmo siga solamente a una parte de la región de piel (lavarse las manos en un lavabo, sin tener que usar una camisa de mangas largas), por lo tanto, se incorpora una variación a este algoritmo con el fin de adaptarlo a este escenario. Como parte de este cambio, el algoritmo no debe rebasar el tamaño máximo de ventana de 80x80 píxeles determinado de forma experimental. La variación incorporada al algoritmo de *CamShift* y el proceso de seguimiento de la región de interés (mano de una persona) se explican en la siguiente sección.

### 4.2.4. Seguimiento de las manos de una persona

Una vez que se obtiene el tamaño y la posición inicial de la ventana que encierra la mano de una persona, el paso siguiente es realizar el seguimiento del objeto encerrado en la misma. A este respecto y atendiendo al tipo de procesamiento de la imagen, los algoritmos de seguimiento o *tracking* se pueden clasificar en: (i) *basados en modelo* y (ii) *basados en características*. Los sistemas de seguimiento basados en modelo realizan la búsqueda de un modelo específico del objeto a seguir. El resultado, generalmente es la posición del objeto en la imagen analizada. Los sistemas de *tracking* basados en características a pesar de ser menos robustos, suelen ser más simples. En este trabajo, se utiliza una variación del algoritmo de seguimiento basado en características propuesto por bradsky y conocido como *CamShift* [16]. Este algoritmo se basa en el seguimiento del color de la piel humana y tiende a agrupar la mayor región de piel detectada en una imagen.

**Algoritmo de CamShift.** Se basa en estadística robusta, es decir, desecha los datos atípicos de la muestra o los que se alejan demasiado del grupo, por lo tanto tiende a eliminar el ruido. El algoritmo trabaja como se muestra en el diagrama de la Figura 4.5:

1. Elección del tamaño inicial de la ventana de búsqueda. En este trabajo, este tamaño se determina de forma experimental al observar la mano manipular objetos conocidos a una distancia fija de una videocámara. El tamaño fijado es de 80x80 píxeles.
2. Elección de la posición inicial de la ventana de búsqueda. Se determina al aplicar el algoritmo de la media cambiante [32] a la imagen resultante de combinar información de color y movimiento. Este algoritmo, obtiene el centroide de una distribución de datos probabilísticos a través de la moda y con base en el cálculo de momentos.
3. Desplazamiento de la media (una o varias veces) y actualización del momento de orden 0. El algoritmo de desplazamiento de la media se aplica a una imagen en escala de grises que indica la probabilidad de que cada píxel pertenezca a la clase piel (como ya habíamos planteado). Para la distribución de probabilidad en una imagen 2D discreta, la posición del centroide de la ventana de búsqueda (pasos 3 y 4) se calcula como sigue:

Obtención del momento de orden cero:

$$M_{00} = \sum_x \sum_y I(x,y) \quad (4.4)$$

Los momentos de orden 1 para  $x$  y  $y$  se obtienen como sigue:

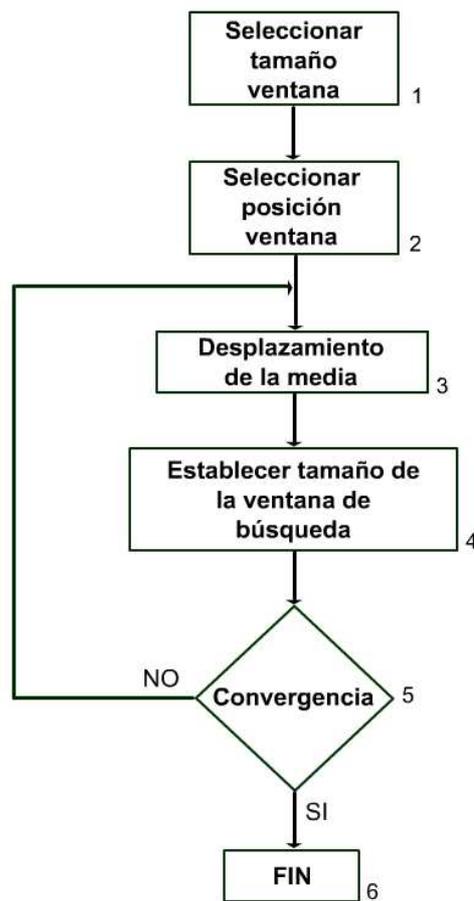


Figura 4.5: Diagrama de flujo del algoritmo CamShift [16] el cual es aplicado en el seguimiento.

$$M_{10} = \sum_x \sum_y xI(x,y) \quad (4.5)$$

$$M_{01} = \sum_y \sum_x yI(x,y) \quad (4.6)$$

El centroide de la ventana se calcula como sigue:

$$x_c = \frac{M_{10}}{M_{00}}, y_c = \frac{M_{01}}{M_{00}} \quad (4.7)$$

donde  $I(x,y)$  es el valor (probabilidad) del píxel en la posición  $(x,y)$  de la imagen, y  $(x,y)$  varían sobre toda la ventana de búsqueda.

4. Elección del nuevo tamaño de la ventana de búsqueda, el cual es una función del momento de orden 0 encontrado en el paso 3. En esta tesis, este tamaño no debe sobrepasar el valor mencionado. El objetivo es que el algoritmo no agrupe a dos regiones de piel similares, por ejemplo, cuando las manos se encuentren juntas o se traslapen.

5. Evaluación de la convergencia. En este trabajo se aplica como criterio de convergencia un total de 10 iteraciones o bien que los desplazamientos de los centroides en los ejes  $x$  y  $y$ , no sobrepasen el valor fijado en el paso 1. Mientras no se cumpla con el criterio de convergencia se continúa con el paso 3.

**Modificación del algoritmo de *CamShift*.** En este trabajo se realiza una variación al algoritmo de *CamShift* [16], con el fin de que la ventana de seguimiento no rebese un tamaño máximo, para esto nos apoyamos en el filtro de Kalman [54]<sup>3</sup>. El filtro de kalman es un estimador lineal en sistemas dinámicos. En este trabajo se utiliza para estimar la siguiente posición del centroide de la mano, esta información se necesita para indicarle al algoritmo de *CamShift* hacia donde dirigir su búsqueda. El procedimiento es el siguiente:

1. Obtención de la posición del centroide de la mano en el momento actual  $t$ . El filtro de Kalman calcula la posición del centroide en el momento  $t$  considerando la información de los momentos como la única información disponible en  $t - 1$ .
2. Ejecución del algoritmo de *CamShift*. El algoritmo de *CamShift* obtiene como dato de entrada la posición del centroide proporcionada por el filtro de Kalman y ajusta la ventana a partir de esta posición, el ajuste no debe rebasar el límite de  $80 \times 80$  píxeles fijado inicialmente de forma experimental. Al terminar su ejecución el algoritmo mantiene la ventana ajustada en una nueva posición.
3. Ajuste de parámetros en el filtro de Kalman. Con el valor de posición calculado por el algoritmo *CamShift*, el filtro de kalman realiza la corrección y ajuste de sus parámetros. El proceso continúa en el paso 1, tomando el valor de posición corregido como la información disponible en  $t - 1$  y estimando la nueva posición del centroide para el tiempo  $t$ .

De esta manera obtenemos un procedimiento para el seguimiento de partes de regiones de piel utilizando el filtro Kalman combinado con el algoritmo de *CamShift*. Un ejemplo de la aplicación de este algoritmo se aprecia en la Figura 4.6.

### 4.3. Extracción y representación de características

Una vez determinado el proceso de segmentación y seguimiento que se va a utilizar, el paso siguiente consiste en seleccionar las características apropiadas, con el fin de reconocer los gestos realizados por la mano de una persona al interactuar con objetos del entorno. Para construir representaciones que capturen de manera confiable las actividades que se realizan en cierto lugar, las características de imágenes de personas y objetos deben ser cuidadosamente identificadas y extraídas. La secuencia de características extraídas debe ser capaz de construir una representación significativa de la actividad que se está realizando. Los métodos más comunes para representar gestos son:

---

<sup>3</sup>El filtro de Kalman es un conjunto de ecuaciones matemáticas que proveen una solución recursiva eficiente del método de mínimos cuadrados. Esta solución permite calcular un estimador lineal, insesgado y óptimo del estado de un proceso en cada momento del tiempo con base en la información disponible en el momento  $t - 1$ , y actualizar, con la información adicional disponible en el momento  $t$ , dichas estimaciones. Este filtro es el principal algoritmo para estimar sistemas dinámicos especificados en la forma de estado-espacio [54].

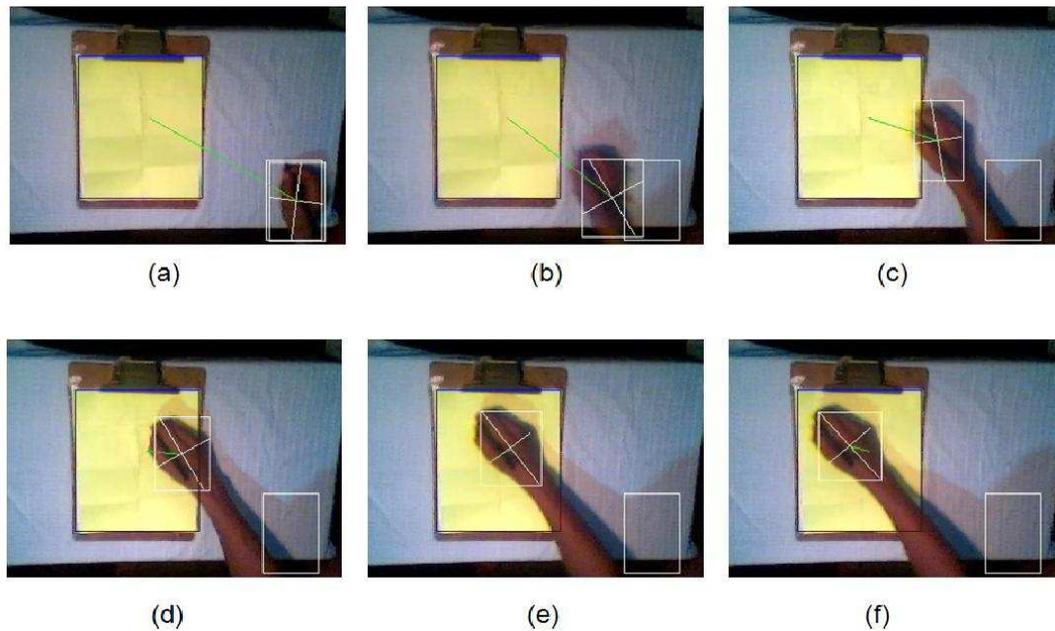


Figura 4.6: Secuencia de imágenes ((a) – (f)) que ilustran el proceso de seguimiento de la mano al realizar el gesto: *Escribiendo en un cuaderno*. Se observa que la ventana de seguimiento se aplica sobre una parte de la región de piel. El cuadro que aparece fijo en la parte inferior de la imagen, indica solamente la posición donde se localizó la región de piel en movimiento dentro de la imagen.

- Características basadas en trayectoria (trayectorias de movimiento, curvas espacio–tiempo)
- Flujo óptico
- Características basadas en regiones

Una de las restricciones más significativas en sistemas de visión de tiempo real, es la sobrecarga computacional requerida al analizar una imagen y construir las representaciones de características de interés, esto conduce a un uso prudente de recursos computacionales. Esta restricción motiva el uso de representaciones basadas en región y trayectoria, ya que generalmente se procesan en menos tiempo que las basadas en flujo óptico. Esto se debe a que las representaciones basadas en flujo óptico se sujetan a modelos  $2D$  y  $3D$  antes que análisis posteriores sean realizados. En esta tesis se aplica una representación de características basadas en trayectorias para reconocer los gestos realizados por una persona, ya que esta representación permite cierta estabilidad ante la presencia de datos ruidosos, tales como los originados en ambientes reales. Asimismo, la trayectoria descrita por la mano de una persona al realizar una actividad presenta las siguientes ventajas:

- La trayectoria del movimiento es la única característica invariante a iluminación, escala, tamaño de la mano, forma o color de objetos.
- La trayectoria del centroide de la mano al realizar una actividad, es independiente de las características físicas de la persona.

Las trayectorias de movimientos realizados por partes del cuerpo humano son representadas normalmente por sistemas de coordenadas (cartesianas, polares, angulares). Varios trabajos han utilizado el sistema de coordenadas cartesiano para el reconocimiento de gestos. Bajo este sistema de

coordenadas, existen diferentes maneras de representar las características de la trayectoria descrita por un gesto. Campbell y otros [17] utilizaron la posición y velocidad en coordenadas cartesianas, la velocidad polar y la velocidad angular, como vector de características para reconocer 6 movimientos de Tai Chi. Por su parte Avilés [4] utiliza la posición, dirección y velocidad en coordenadas cartesianas para representar los movimientos descritos por la mano de una persona especificando comandos a robots. Los ángulos formados por desplazamientos relativos, entre partes del cuerpo humano se han aplicado también para describir el movimiento de gestos o actividades [94]. Yoon y otros [125] utilizan un vector de características formado por la orientación y magnitud en coordenadas polares y la velocidad en coordenadas cartesianas, con el fin de reconocer caracteres alfabéticos descritos por la mano. Por su parte, Darnell [76] utiliza solamente la posición de una secuencia de puntos descrita en coordenadas cartesianas con el fin de reconocer los gestos realizados por las manos de una persona al interactuar con objetos del entorno. Darnell [76], considera que el uso de información contextual apoya el proceso de reconocer gestos humanos y por lo tanto, no es necesario el uso de complicados vectores de características.

Generalmente, en los trabajos basados en trayectorias, el análisis de la misma se realiza a través de conectar una secuencia de puntos descritos por el centroide de la mano de una persona al realizar una actividad, tal como se muestra en la Figura 4.7, donde se observa la trayectoria descrita por el centroide de la mano de una persona al realizar la actividad *contestar el teléfono*. En la Figura 4.8, se observa la conexión de los puntos descritos por el centroide de la mano al realizar un gesto, así como otros datos adicionales tales como, el ángulo entre dos puntos consecutivos y el punto medio de la trayectoria. En el trabajo realizado por Montero y Sucar [113], se mostró un procedimiento exhaustivo<sup>4</sup> para la selección de las características utilizadas en esta tesis. El criterio para la selección se basa en el rendimiento del proceso de reconocimiento de gestos. Las características inicialmente seleccionadas fueron las siguientes:

- Posición  $x$  en coordenadas cartesianas
- Posición  $y$  en coordenadas cartesianas
- Magnitud en coordenada polar ( $\rho$ )
- Orientación en coordenada polar ( $\phi$ )
- Velocidad en coordenadas cartesianas ( $v$ )
- Código de cadena ( $CC$ ) discretizado en 16 símbolos.

Sin embargo, los resultados en el reconocimiento de gestos donde aparecían las siguientes características: posición en coordenadas cartesianas ( $x,y$ ) y código de cadena ( $CC$ ), fueron deficientes ( $< 60\%$ ), por lo tanto, no se consideraron. En esta sección, se muestran aspectos relacionados con las características<sup>5</sup> que ofrecieron mayores porcentajes ( $> 60\%$ ) en el proceso de reconocimiento de gestos y son las siguientes:

- Magnitud en coordenada polar ( $\rho$ )
- Orientación en coordenada polar ( $\phi$ )
- Velocidad en coordenadas cartesianas ( $v$ )

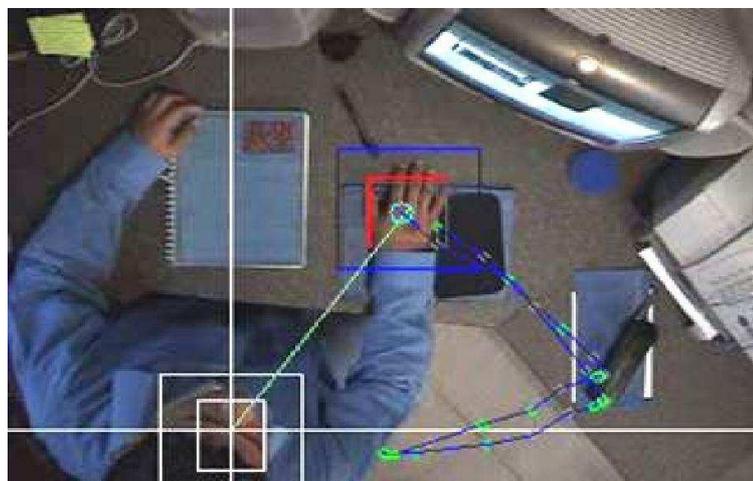


Figura 4.7: Trayectoria descrita por el centroide de la mano al *contestar el teléfono*

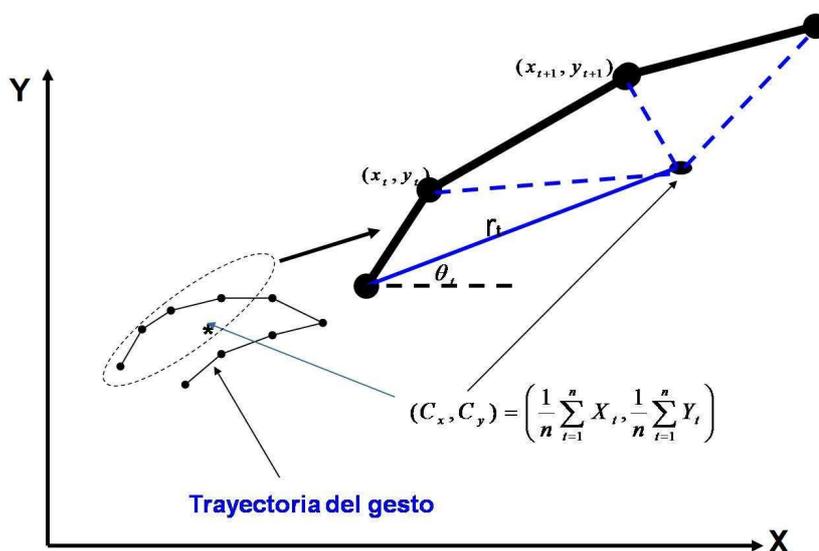


Figura 4.8: La imagen ilustra la trayectoria del centroide de la mano al realizar un gesto (la trayectoria es ficticia con fin de facilitar la explicación). El punto medio  $(C_x, C_y)$  de la trayectoria es distinto para cada gesto. A partir de este punto se obtienen las características (posición, velocidad, magnitud y orientación en coordenadas polares) que representan a cada gesto. Para esto se analizan todos los puntos de la trayectoria tomando dos puntos en secuencia (ver ampliación).

Por lo tanto, el vector de características que describe la trayectoria del centroide de la mano al interactuar con objetos del entorno está formado por  $V = [\rho \ \phi \ v]$ . Se va a trabajar con datos normalizados, la obtención de estos valores se muestra a continuación.

Punto medio:

$$(C_x, C_y) = \left( \frac{1}{n} \sum_{t=1}^n X_t, \frac{1}{n} \sum_{t=1}^n Y_t \right) \quad (4.8)$$

donde  $(C_x, C_y)$  indica el punto medio de la trayectoria de un gesto (ver Figura 4.8). De esta forma, cada gesto tiene un punto medio diferente.

Ángulo:

$$\theta_t = \tan^{-1} \left( \frac{Y_t - C_y}{X_t - C_x} \right) \quad (4.9)$$

$\theta_t$  es el ángulo obtenido entre cada punto de la trayectoria del gesto y el punto medio (centroide) de todos los puntos que describen la trayectoria (ver Figura 4.8).

Distancia:

$$r_t = \sqrt{(X_t - C_x)^2 + (Y_t - C_y)^2} \quad (4.10)$$

$r_t$  es la distancia (magnitud) entre el punto medio de la trayectoria del gesto y cada punto individual que forma la trayectoria del mismo. Con fin de reducir los cálculos debidos al manejo de distintos tipos de datos, las características mencionadas son normalizadas. El proceso es el siguiente:

$$r_{max} = \max_{t=1}^n (r_t) \quad (4.11)$$

$r_{max}$ , representa la distancia máxima entre las coordenadas del punto medio (centroide) de la trayectoria y cualquiera de los demás puntos que forman la misma.

$$\rho_t = \frac{r_t}{r_{max}}, \phi_t = \frac{\theta_t}{2\pi} \quad (4.12)$$

$\rho_t$ , es el valor normalizado entre 0,0 – 1,0 que relaciona la distancia máxima a partir del punto medio de la trayectoria del gesto y cada uno de los otros puntos que la integran. A su vez,  $\phi_t$  es el valor normalizado del ángulo descrito en la trayectoria.

---

<sup>4</sup>Se realizó el manejo de las características de manera individual y combinadas (63 diferentes combinaciones).

<sup>5</sup>En el apéndice A, se ilustra el procedimiento de selección con el conjunto inicialmente seleccionado.

$$V_t = \sqrt{(X_t - X_{t+1})^2 + (Y_t - Y_{t+1})^2} \quad (4.13)$$

$$V_{max} = \max_{t=1}^n (V_t) \quad (4.14)$$

$$v_t = \frac{V_t}{V_{max}} \quad (4.15)$$

El factor  $v_t$  representa el valor de la velocidad entre dos puntos y está normalizada entre 0.0 - 1.0.

$$F = \{(\rho_1, \phi_1, v_1), \dots, (\rho_n, \phi_n, v_n)\} \quad (4.16)$$

Finalmente,  $F$ , representa la trayectoria descrita por el gesto, bajo el sistema de coordenadas  $\rho - \phi - v$ .

Las características descritas fueron combinadas de manera exhaustiva<sup>6</sup> con el fin de determinar cual de ellas nos proporciona el menor conjunto representativo para ser utilizado en el reconocimiento de gestos. La selección de este conjunto de características se realizó aplicando como criterio el rendimiento de los modelos ocultos de Markov en el reconocimiento de los gestos modelados. Bajo este enfoque la combinación de características formada por la magnitud  $\rho$ , y la orientación  $\phi$ , ambas en coordenadas polares son las que ofrecen mayor capacidad discriminante (Ver Figura 4.12) durante el proceso de reconocimiento de gestos [113]. Las características seleccionadas se van a utilizar para representar la trayectoria descrita por el centroide de la mano al realizar un gesto. Durante el modelado de cada gesto se genera una cantidad considerable de datos continuos necesarios para que el modelo *aprenda* a reconocerlos. Por lo tanto, con el fin de disminuir este trabajo computacional se procede a agrupar las secuencias de datos continuos en clases de datos discretos que los representen, a este proceso se le conoce como: discretización de características o cuantización vectorial.

### 4.3.1. Discretización de las características

Existen varios métodos para realizar el proceso de discretizar un flujo de datos continuos, en este trabajo se aplica el algoritmo *k-medias* [37]. Para obtener mayor información de los métodos existentes se puede consultar el trabajo realizado por Gray [38].

Las características extraídas son cuantificadas con el fin de obtener símbolos discretos utilizados por los modelos ocultos de Markov (HMMs) [95]. A partir de las trayectorias descritas por los gestos en el sistema de coordenadas  $\rho\phi v$  se crean símbolos discretos utilizando el algoritmo *k-medias*. Lo que se busca es simplificar un conjunto muy amplio de datos, generados por la trayectoria de cada gesto en un conjunto más compacto representado por  $k$  clases. El algoritmo *k-medias* es un método simple y eficiente para agrupar  $k$  clases en un espacio de características. Este algoritmo se basa en

---

<sup>6</sup>Ver Apéndice A.

la distancia mínima entre el punto medio de cada clase ( $k$ ) y los puntos de las características. Para realizar el agrupamiento de un conjunto de datos en  $k$  clases, este algoritmo realiza los siguientes pasos:

1. **Inicialización.** Se construye un Libro de Códigos<sup>7</sup> ( $x_i, 1 \leq i \leq k$ ).
2. Repetir lo siguiente para cada vector de entrenamiento:  
**Clasificación.** Se clasifica a cada elemento de los vectores de entrenamiento  $x_k$  en uno de los grupos  $C_i$  usando el clasificador de mínima distancia.  
**Actualizar el Libro de Códigos.** Se actualiza el Libro de Códigos calculando el punto medio de los vectores de entrenamiento en cada grupo.
3. **Finalizar.** Se termina el agrupamiento cuando la diferencia entre la distancia de cada punto a los puntos medios de las clases es mínima, de otra forma se continúa en el paso 2.

En otras palabras, para que el algoritmo inicie su proceso iterativo de agrupamiento de un conjunto de datos en  $k$  clases, necesita que se le proporcione de antemano el valor de  $k$ , es decir, el número de las clases. En la Figura 4.9 se puede observar un ejemplo de la operación de este algoritmo, donde se determina un valor para  $k$  igual a 32 tomando como datos de entrada una secuencia de 100 datos continuos correspondientes a la ejecución de 6 gestos diferentes. Como resultado del proceso de cuantización vectorial (VQ), se obtiene un libro de códigos (*Codebook*). Este libro de códigos contiene un número de símbolo y la coordenada del centroide de cada clase. En este trabajo, se manejaron libros de código de tamaño 32, 64 y 128, obteniéndose los mejores resultados con un libro de códigos de tamaño igual a 64, es decir con 64 símbolos discretos. El proceso del reconocimiento del VQ es el siguiente. Se introduce un vector ( $\rho\phi v$ ) representando los datos de un gesto, se calcula la distancia Euclídea con cada una de las clases previamente definidas, se determina su pertenencia a alguna de las clases utilizando la distancia mínima. En este punto se tienen los símbolos discretos de observación utilizados para entrenar a los Modelos Ocultos de Markov (HMMs) [95].

## 4.4. Reconocimiento de gestos usando HMMs

Los modelos ocultos de Markov (HMMs) [95] son una técnica estadística de amplio uso en el reconocimiento de patrones de datos secuenciales. Yamato y otros, desarrollaron en 1991 uno de los primeros sistemas basados en HMMs para el reconocimiento de gestos [121]. A partir de entonces, ha existido un sustancial incremento de investigadores de la comunidad de visión que han adoptado a los HMMs como el método preferido para caracterizar gestos y actividades humanas [76, 98, 122, 125]. Asimismo, han existido varias modificaciones que se han realizado a la estructura básica de estos modelos motivadas por los deseos de extender la aplicación de los HMMs a una variedad más amplia de problemas. Una razón para la popularidad de los HMMs ha sido su habilidad para caracterizar de manera precisa, datos que exhiben una estructura secuencial en presencia de ruido y ligeras variaciones. Las representaciones de movimiento basadas en estado tal como los modelos ocultos de Markov, son adecuadas para representar acciones y gestos, los cuales se caracterizan por patrones de movimiento con algún orden natural. A continuación, se presenta una definición completa de estos modelos.

---

<sup>7</sup>El Libro de Código está formado por el número total de símbolos discretos con los cuales se entrenan y evalúan a los HMMs. También se les conoce a este conjunto de símbolos como alfabeto [95].

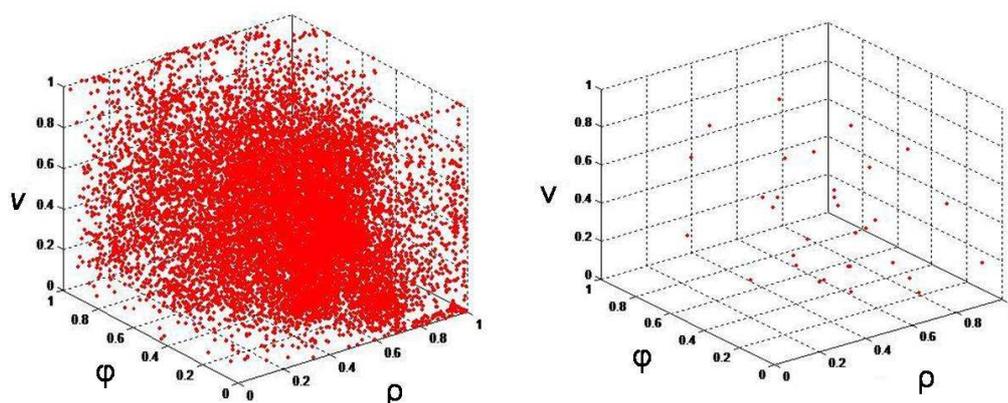


Figura 4.9: Ilustración del proceso de agrupamiento de datos aplicando el algoritmo *k-medias* [38]. La imagen de la izquierda muestra un flujo de datos continuos correspondientes a 100 secuencias de 6 gestos distintos. La imagen derecha muestra los datos discretizados en 32 clases. Las coordenadas de las figuras son la magnitud  $\rho$  y orientación  $\phi$  en coordenadas polares y la velocidad  $v$  en coordenadas cartesianas.

#### 4.4.1. Definición

Los HMMs pueden ser descritos como una máquina de estado finito caracterizada por dos procesos estocásticos, uno de los cuales determina la transición entre los estados y no es observable, el otro, genera observaciones de salida para cada estado. Los estados no son determinados de manera directa a partir de las observaciones, por lo tanto, son ocultos. Por ejemplo, considere tres estados con probabilidades de transición y respuestas de salida, como se muestra en la Figura 4.10. Se nota que cada estado genera una única salida, es decir, la salida es determinista, así que, es posible recuperar la secuencia de estados a partir de la secuencia de salida. Este es un ejemplo de cadena de Markov. Sin embargo, si cada estado puede generar cualquiera de las tres salidas, entonces, no es posible recuperar sin ambigüedad la secuencia de estados a partir de las observaciones, tal como se ilustra en la Figura 4.11, entonces, los estados son ocultos. Este ejemplo define a un típico HMM. La característica de estos modelos, consiste en su habilidad para encontrar la secuencia más probable de estados que pudo haber generado una secuencia dada de observaciones.

La definición formal de los elementos de un modelo oculto de Markov con observaciones discretas se realiza utilizando las siguientes declaraciones:

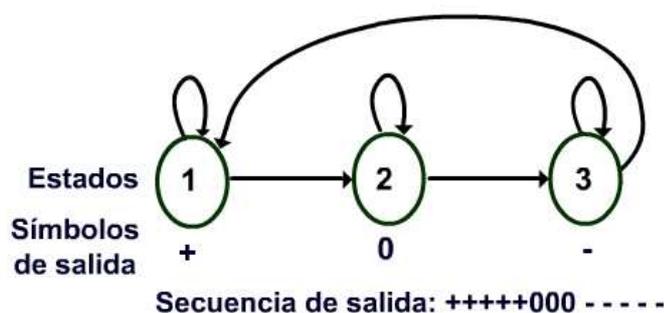


Figura 4.10: Ilustración de una cadena de Markov donde se muestran los estados con probabilidades de transición y salida determinística. La secuencia de estados puede determinarse a partir de la salida.

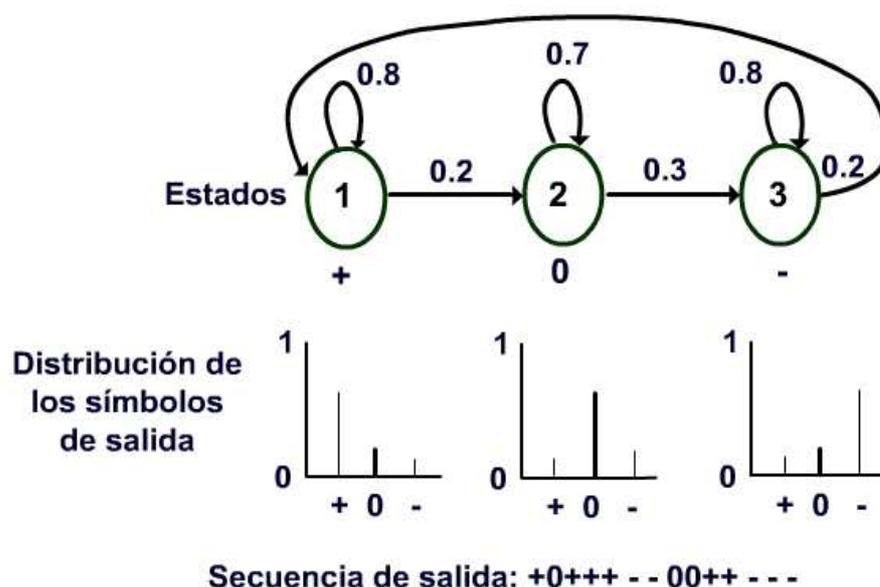


Figura 4.11: La Figura ilustra la topología del modelo oculto de Markov utilizado en este trabajo. Las probabilidades de transición y de salida mostradas son ficticias.

- $N$ , indica el número de estados del modelo, previamente definidos.
- $M$ , define el número de símbolos de observación en el alfabeto de símbolos  $V$ , tal que  $V = v_1, v_2, \dots, v_M$ .
- $T$ , es la longitud de la secuencia de observación  $O$ , la cual está dada por  $O = (o_1 o_2 \dots o_T)$ .
- $s$ , es el espacio de estados, el cual se particiona en  $N$  estados, tal que  $s = s_1, s_2, \dots, s_N$ . El estado del modelo en el tiempo  $t$  está dado por  $q_t \in s, 1 \leq t \leq T$ .
- $A$ , es la matriz de probabilidades de transición, es decir,  $A = a_{ij}$  donde

$$a_{ij} = P(q_{t+1} = s_j | q_t = s_i), 1 \leq i, j \leq N \quad (4.17)$$

$q_t$  denota el estado actual. Las probabilidades de transición deben satisfacer la siguiente restricción estocástica:

$$a_{ij} \geq 0, y, \sum_{j=1}^N a_{ij} = 1, 1 \leq i, j \leq N \quad (4.18)$$

- $B$ , es la matriz de distribución de probabilidades para los símbolos de observación, esto es,  $B = b_j(k)$  donde,

$$b_j(k) = P(o_t = v_k | q_t = s_j), 1 \leq j \leq N, 1 \leq k \leq M \quad (4.19)$$

$o_t$  es la observación en el tiempo  $t$ , y  $v_k$  indica el  $k^{\text{ésimo}}$  símbolo de observación en  $V$ . Asimismo, se debe satisfacer la siguiente restricción estocástica:

$$b_j(k) \geq 0, y, \sum_{k=1}^M b_j(k) = 1 \quad (4.20)$$

- La distribución inicial de estados, está definida por  $\Pi = \pi_i$ , donde

$$\pi_i = P(q_t = s_i). \quad (4.21)$$

Por conveniencia, un HMM con distribuciones de probabilidad discreta puede representarse utilizando la notación compacta,

$$\lambda = (A, B, \Pi)$$

Existen generalmente tres problemas asociados con el uso de los modelos ocultos de Markov [95], y son los siguientes:

- Dados los parámetros del modelo, obtener la probabilidad de un secuencia de salida en particular. Este problema se resuelve generalmente con el algoritmo de avance-retroceso o Baum-Welch. En este trabajo se aplica el algoritmo de Viterbi para resolver este problema.
- Dados los parámetros del modelo, encontrar la secuencia de estados ocultos más probable que puedan haber generado una secuencia de salida dada. Este problema se resuelve con el algoritmo de Viterbi.
- Dada una secuencia de salida o un conjunto de tales secuencias, encuéntrese el conjunto de estados de transición y probabilidades de salida más probables. En otras palabras, se realiza el entrenamiento de los parámetro del HMM a partir de una secuencia de datos. Este problema se resuelve con el algoritmo de Baum-Welch.

#### 4.4.2. Vectores de observación

Como se indicó previamente en la Sección 4.3, se realizó un procedimiento para encontrar un grupo de características que permita caracterizar apropiadamente los movimientos de la mano [113]. Aplicando segmentación basada en *color* y *movimiento*, se determinaron las regiones que representan las manos. Aunque existen varias métricas que pueden ser utilizadas para representar características, tales como: el área de píxeles que contienen la región de piel, elongación, excentricidad y ángulo de menor inercia. En este trabajo se aplican características basadas en trayectorias tomando como

punto de partida la posición  $(x, y)$  del centroide de la mano en coordenadas cartesianas. Para modelar la mayoría de las acciones realizadas por la mano de una persona, el centroide es generalmente suficiente. Las características seleccionadas del grupo analizado son la magnitud ( $\rho$ ) y orientación ( $\phi$ ) en coordenadas polares, así como la velocidad ( $v$ ) en coordenadas cartesianas. La trayectoria de cada gesto genera un vector compuesto por un conjunto de valores  $(\rho, \phi, v)$ , los cuales al ser discretizados generan los símbolos de observación utilizados en el entrenamiento de los HMMs. Se utilizaron durante la etapa de pruebas experimentales diferentes valores (16, 32, 64, y 128) para los símbolos de observación,  $M$ . Las gráficas que ilustran estos resultados se describen en el Apéndice A.

#### 4.4.3. Datos de entrenamiento

En este trabajo se asume que todos los gestos son distintos y repetibles. Para que los sistemas de reconocimiento de gestos sean independientes del usuario, los conjuntos de datos de entrenamiento deben ser construidos a partir de observaciones generadas por distintas personas. Sin embargo, el uso de observaciones basadas en la trayectoria descrita por un centroide, permiten el entrenamiento de modelos utilizando un solo usuario y generan modelos eficientes e independientes del mismo. A menos que se especifique de otra manera, todos los gestos reconocidos en este trabajo son debidos a interacciones entre la mano derecha<sup>8</sup> de una persona y un objeto del entorno. Los HMMs son una técnica manejada por datos, esto indica que dependiendo de la cantidad de los datos utilizados durante el proceso de entrenamiento, así como el manejo de otras variables (número de estados ocultos, topología del modelo), es la confiabilidad de su operación. Sin embargo, no existe un método que nos indique de manera precisa cuantos datos son suficientes. Por lo tanto, en este trabajo se realizó una prueba experimental para determinar el conjunto de datos necesarios para el entrenamiento del modelo, durante este proceso se analizaron 5 casos de prueba obtenidos a partir de gestos realizados en un ambiente de oficina. Los datos extraídos para cada caso fueron los siguientes: (i) 40 secuencias de cada gesto, (ii) 60 secuencias de cada gesto, (iii) 80 secuencias de cada gesto, (iv) 90 secuencias de cada gesto, y (v) 100 secuencias de cada gesto. Se manejó el 70 % del conjunto de datos en cada caso para el entrenamiento y el 30 % para la evaluación, de tal forma que, en el primer caso, se destinaron 28 datos para el entrenamiento y 12 para la evaluación del modelo. Para los demás casos se procedió de igual manera.

La Figura 4.12, muestra los resultados del porcentaje promedio obtenido en el reconocimiento de los gestos modelados por los HMMs. El valor máximo obtenido en el proceso de reconocimiento fue de 97 % y se alcanzó al manejar 100 secuencias para cada gesto, el modelo utilizado en este caso tiene 10 estados ocultos y maneja 64 símbolos de observación. Se observa a partir de la Figura 4.12, que el porcentaje de reconocimiento se incrementa significativamente al aumentar el número de datos utilizados en el entrenamiento. Sin embargo, en los últimos casos, este incremento no resulta significativo ( $< 10\%$ ). Por lo tanto, a partir de este análisis, se determina que el conjunto de datos de entrenamiento que se va a utilizar en este trabajo es de 100 secuencias para cada gesto.

Las 100 repeticiones para cada actividad fueron realizadas por la misma persona, y segmentadas manualmente de vídeo. El escenario utilizado para este grupo de gestos fue un típico ambiente de oficina, el conjunto de gestos realizados son los siguientes: *tomar el teléfono, escribir/borrar en una hoja, usar el mouse, hojar un libro y tomar una taza*. Las 100 secuencias de cada gesto generaron un total de 19,037 observaciones, de las cuales 13,289 fueron utilizadas para entrenamiento y 5,748 para la evaluación. Es decir, la relación de los datos utilizados para el proceso de entrenamiento y

---

<sup>8</sup>Esto no implica que el modelo funciona solamente para personas diestras, sino, que los datos de entrenamiento se obtuvieron de una persona diestra.

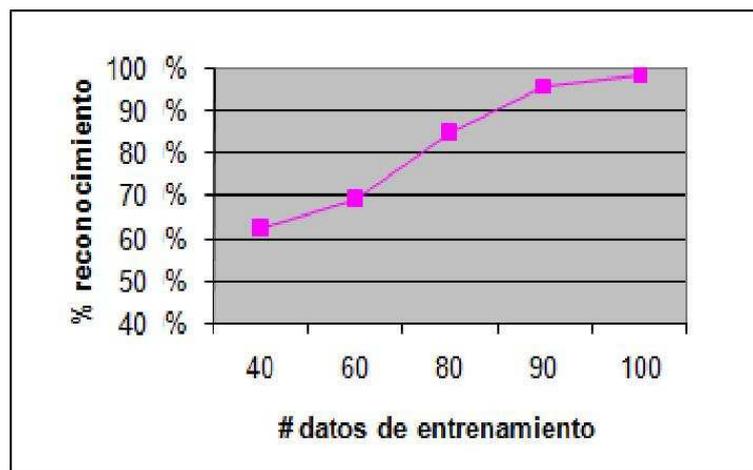


Figura 4.12: Determinación del número de datos utilizados en el proceso de entrenamiento del modelo. Los resultados que se muestran, son el porcentaje de reconocimiento promedio obtenido al analizar 5 casos de prueba. El modelo manejado es de 10 estados ocultos y 64 símbolos observables. Las características utilizadas son la magnitud ( $\rho$ ) y orientación ( $\phi$ ) en coordenadas polares.

evaluación fue de 70 – 30. Por otro lado, la topología HMM que reportó mayor exactitud en el reconocimiento fue la *izquierda – derecha*, o  $L - R$  (por sus siglas en inglés). La estructura  $L - R$  puede modelar fácilmente secuencias de observaciones cuya estructura cambia en el tiempo. En estos modelos, la transición entre estados ocurre de izquierda a derecha conforme pasa el tiempo, esta propiedad es adecuada para el reconocimiento dinámico de gestos.

#### 4.4.4. Entrenamiento de los HMMs

Considerado como el aspecto más difícil para utilizar un HMM, el entrenamiento debe generar un modelo parametrizado que caracterice apropiadamente un proceso secuencial. Las observaciones que representan gestos típicos, llamadas el conjunto de datos de entrenamiento, son usadas para ajustar de manera apropiada los parámetros ( $A, B, \Pi$ ) del HMM. El objetivo es maximizar  $P(O|\lambda)$ . En este trabajo, se aplica el algoritmo iterativo de *Baum – Welch* [95], para realizar el entrenamiento de los diferentes modelos ocultos de Markov ( $\lambda$ ), correspondientes a cada gesto. Los parámetros del modelo oculto de Markov se inicializan con valores equiprobables distintos de cero y sujetos a las restricciones probabilísticas indicadas por las Ecs. (4,2 y 4,4). El criterio de paro utilizado para el proceso de entrenamiento se basa en que se cumpla lo siguiente:

$$\frac{P(O|\lambda^{(l)}) - P(O|\lambda^{(l-1)})}{P(O|\lambda^{(l)})} < \delta \quad (4.22)$$

En este trabajo se emplea un  $\delta = 0,000001$ . El algoritmo de *Baum – Welch* no siempre obtiene el máximo global, aunque siempre encuentra el máximo local. Sin embargo, esto no representa un problema significativo en el proceso de reconocimiento de acuerdo a datos experimentales obtenidos con los escenarios utilizados.

### 4.4.5. Reconocimiento de gestos

Cada gesto que se pretende reconocer va a ser representado por un HMM. El problema de evaluación consiste en encontrar la probabilidad de una secuencia de observaciones  $O = (o_1 o_2 \dots o_T)$ , dado un modelo  $\lambda$ . Esta evaluación debe hacerse para cada modelo, el modelo con la mayor probabilidad es seleccionado. En este trabajo, se aplica el algoritmo de Viterbi [95], con el fin de reconocer los gestos. Este algoritmo, identifica el gesto más probable al evaluar  $P(O|\lambda)$ . Aplicando la expresión anterior, se puede ver como un caso específico del algoritmo *forward – backward* [95], donde se selecciona en cada paso temporal la trayectoria más probable. Mientras que el algoritmo *forward – backward* obtiene  $P(O|\lambda)$  a través de sumar  $P(O, q|\lambda)$  sobre todas las posibles secuencias de estados  $q$ , el algoritmo de Viterbi obtiene el valor óptimo de  $P(O, q|\lambda)$  sobre todas las  $q$ . Aunque se considera menos robusto que el algoritmo de *forward – backward*, el algoritmo de Viterbi es generalmente más eficiente. La complejidad del algoritmo de Viterbi es del orden de  $N^2T$  multiplicaciones.

Datos proporcionados por pruebas experimentales indican que el mayor porcentaje de reconocimiento (97%) se obtuvo al utilizar la combinación de características magnitud  $\rho$  y orientación  $\phi$  en coordenadas polares. El número de estados para los HMMs donde se alcanzó este porcentaje de reconocimiento fue de 10, y con 64 símbolos de observación (ver Figura 4.13). Los porcentajes de reconocimiento mostrados en estas pruebas son el promedio del total de los gestos reconocidos. Es decir, no reflejan el reconocimiento individual de cada uno de los gestos, sino más bien el promedio de los mismos, por lo que puede utilizarse como una métrica del rendimiento del sistema bajo estas condiciones. Una vez determinado el conjunto de características representativo para el reconocimiento de los gestos, se va a integrar al modelo la información de contexto. Enseguida se describen las etapas para incorporar el contexto al proceso de reconocimiento de gestos.

## 4.5. Reconocimiento de objetos

Para realizar el reconocimiento de objetos se asume lo siguiente: (a) solamente existe un objeto de cada clase en la imagen y (b) cada objeto tiene un color distintivo que lo distingue de los demás. El proceso realizado se describe a continuación.

Para reconocer los objetos de interés en un escenario, esto es, los objetos con los que interactúa la mano de una persona al realizar una actividad, se aplica en este trabajo un enfoque basado en color. El espacio de color utilizado es el *HSV* [37] y la representación de los datos es a través de histogramas de color [107]. Durante la interacción con la mano del usuario, los objetos pueden estar sujetos a varias condiciones, lo que hace que el sistema de reconocimiento enfrente los siguientes problemas:

- Distracciones en el fondo (*background*) de la imagen.
- Identificar al objeto desde varios puntos de vista.
- Oclusiones.
- Condiciones de iluminación variable.

Por lo tanto, se busca una técnica que permita la representación y reconocimiento de objetos, invariante a:

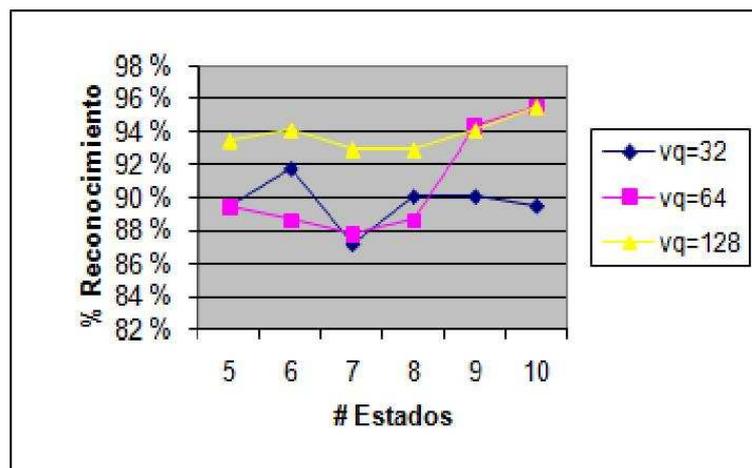


Figura 4.13: Reconocimiento obtenido al emplear como característica la combinación orientación  $\phi$  y magnitud  $\rho$  polares, variando el número de estados y tamaño del libro de códigos.

- Escala.
- Rotación y/o traslación.
- Robustez a cambios de forma y tamaño.
- Iluminación.

Las técnicas basadas en características geométricas [37], aunque permiten la extracción confiable de características de bajo nivel (bordes, esquinas, líneas) como una forma primaria de identificación de objetos, y son estables ante cambios de vista e iluminación, generan una gran cantidad de falsas correspondencias ante presencia de ruido, aún ante los objetos más simples. Swain [107], comprobó que el color puede utilizarse para reconocer de manera confiable a objetos en una imagen. De acuerdo con el algoritmo de Swain y Ballard [107], la robustez a escala y rotación se proporciona a través del color. La robustez a cambios de ángulos de visión y a oclusión parcial se maneja por el uso de histogramas.

Los histogramas son invariantes a rotación y traslación considerando un eje perpendicular al plano de la imagen, muestra ligeras variaciones ante cambios de ángulos de vista, cambio de escala y oclusión. Para que el color se aplique de manera confiable al reconocimiento de objetos se tienen que remover los factores que pueden causar confusión. Afortunadamente varios autores [28, 34], han mostrado que las imágenes pueden ser normalizadas con el fin de remover estas dependencias. En este trabajo se aplica un enfoque basado en color y representación por histogramas al proceso de detección y localización de objetos, el cual es una variación de los trabajos de Swain [107], Finlayson [28] y Funt [34]. El procedimiento utilizado se muestra en el diagrama de la Figura 4.14, los pasos realizados se describen a continuación.

**Obtención de muestras y representación a través de histogramas.** Para cada objeto de interés en un escenario se toman muestras de color para formar la base de datos de objetos. El modelo de color utilizado en este trabajo es el *HSV* [37], de donde solamente se emplean los valores de  $h - s$  (croma y saturación), con el fin de disminuir el efecto de la variación luminosa (Swain aplicó en su método el espacio de color RGB). Los valores del espacio de color son normalizados en el intervalo  $[0 - 1]$ . El histograma de color para cada objeto, se forma contando el número de veces que cada combinación

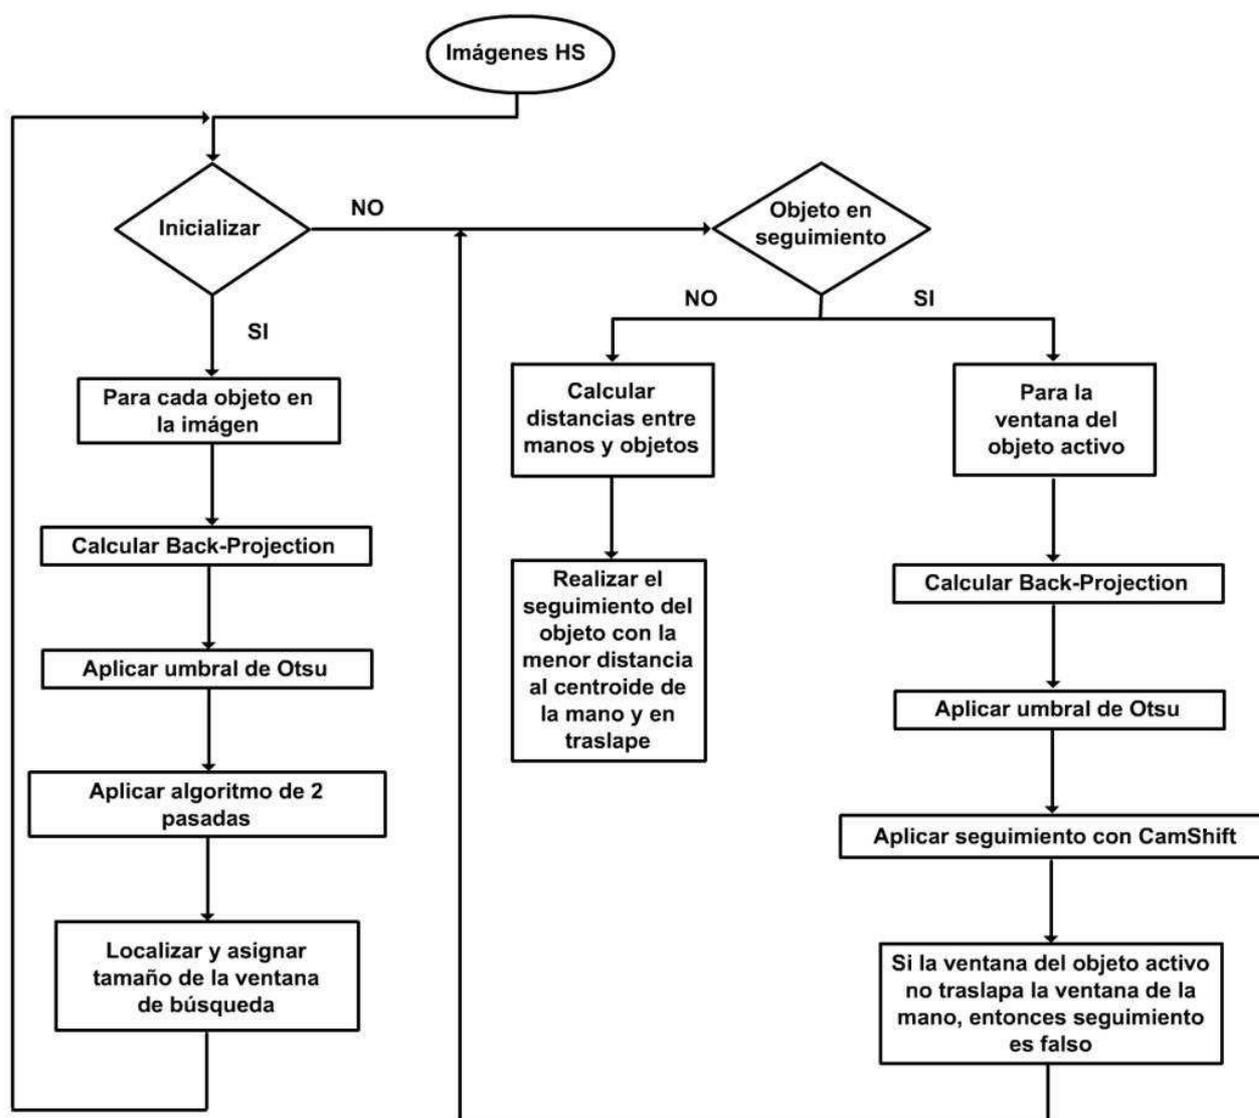


Figura 4.14: Diagrama que ilustra el proceso de detección, localización y seguimiento de objetos.

de color  $h - s$  ocurre en la imagen. Los histogramas se dividen en segmentos o *bins* con fin de mejorar su rendimiento. En este trabajo, se utilizan histogramas de 32 segmentos o *bins*, se ha demostrado que es un tamaño apropiado para este tipo de representaciones [52].

**Reconocimiento de objetos aplicando correspondencia de histogramas.** Para detectar y localizar a cada uno de los objetos de interés en una secuencia de imágenes se emplea el algoritmo de *back - projection* propuesto por Swain [107]. Este método representa a los objetos por medio de histogramas los cuales son almacenados en una base de datos, al analizar una imagen en busca de un objeto, primero obtiene el histograma de la imagen y lo compara con los modelos almacenados, al encontrar una correspondencia agrupa los píxeles en regiones homogéneas. Swain demostró que la identificación de objetos, aplicando la correspondencia de un histograma de color a partir de una región de la imagen, con un histograma de color tomado de la muestra de un objeto, es una técnica robusta a cambios en la escala del objeto, cambios en la forma del mismo, cambios en la orientación y oclusión parcial. Las condiciones anteriores, son comunes en sistemas de reconocimiento de gestos, donde una persona realiza actividades a través de interactuar con objetos del entorno. La búsqueda de objetos en este trabajo es determinada en los primeros 5 cuadros de la secuencia de imágenes, los

objetos se buscan uno a la vez, para esto se aplican los siguientes pasos:

1. Para segmentar objetos se aplica el algoritmo de *back-projection* [107], y se obtiene una imagen en escala de grises, donde el objeto de interés es el que tiene píxeles con valores cercanos a 255. En este algoritmo, el objeto que se busca debe estar representado por un histograma a color  $M$  multidimensional (en este trabajo se maneja  $h - s$ ). Asimismo, se obtiene el histograma de la imagen  $I$  que se está analizando, y se calcula un tercer histograma  $R$ , resultado de dividir el histograma del modelo entre el histograma de la imagen. El histograma  $R$ , se mapea sobre la imagen, los valores en la misma son reemplazados por los indizados por  $R$ . Al aplicar un proceso de convolución a este histograma, y considerando las suposiciones iniciales se localiza el objeto dentro de la imagen.
2. A la imagen en escala de grises se le aplica el algoritmo de Otsu [83], con el fin de determinar los valores de umbral óptimos adaptables a las condiciones de iluminación, el resultado es una imagen binaria. Los valores de umbral obtenidos en este paso se necesitan como argumento en la siguiente etapa.
3. Para determinar las coordenadas de la ventana donde se ubica un objeto de interés, se aplica el algoritmo de segmentación de dos pasadas (*Two-Pass Algorithm* [69]) el cual examina toda la imagen (la imagen binaria obtenida en el paso anterior), y agrupa los píxeles en regiones homogéneas, con esto se obtiene la región de mayor tamaño que se asume es el objeto detectado. Este algoritmo proporciona (entre otros datos) las coordenadas de la ventana que encierra a la región de mayor tamaño, y es la que se utiliza como el tamaño máximo de ventana en la fase de seguimiento.

La detección y localización de objetos aplicando el proceso mencionado se muestra en la Figura 4.15, donde se ilustran los dos escenarios utilizados en este trabajo. En la imagen derecha de la figura se localizan los siguientes objetos: (a) *Mouse*, se detecta y encierra en una ventana de color verde, (b) *Pantalla*, se muestra encerrada en una ventana de color aguamarina, (c) *textitHoja de escribir*, aparece encerrado en un rectángulo de color azul, (d) *Libro*, aparece encerrado en un rectángulo de color rojo. En la imagen izquierda de la figura se localizan los siguientes objetos: (a) *Jabón*, se encierra en un rectángulo de color verde, (b) *Grifo*, se muestra encerrado en color azul, (c) *Toalla*, aparece encerrada en un rectángulo de color rosa.

**Seguimiento.** Una vez que se localiza a cada objeto de interés en un escenario conocido, el paso siguiente es realizar su seguimiento, aplicando para ello el algoritmo de *CamShift* [16]. El proceso de seguimiento se aplica sobre el objeto que se determina está en contacto con la mano del usuario. Es necesario mantener el proceso de segmentación del objeto durante el seguimiento para esto se utiliza el algoritmo de *Backprojection* [107]. Antes de realizar el seguimiento se determina la cercanía entre la mano y cada uno de los objetos calculando la distancia entre el centroide de la mano y el centroide de cada uno de los objetos. En la Figura 4.16(a) y (b) se muestra un ejemplo, se observa la identificación de los objetos de interés en dos escenarios (oficina y lavabo). Asimismo, se observan los centroides de cada objeto y el de la mano del usuario, la distancia se visualiza con líneas trazadas entre los centroides de los objetos y mano del usuario respectivamente. El objeto que se considera más cercano a la mano del usuario aparece con línea de color rojo uniendo los centroides. Posteriormente se determina el contacto con uno de los objetos a través del traslape de las ventanas, tanto de la mano como del objeto, si este traslape persiste durante algunos cuadros (de forma semejante a la realizada por Darnell [76]) se asume que la persona está haciendo contacto con el objeto y probablemente proceda a su manipulación.

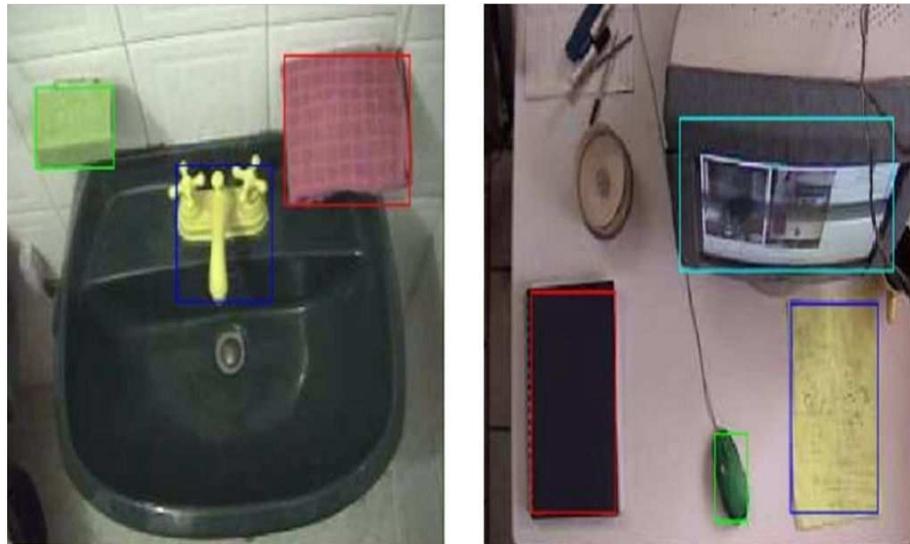


Figura 4.15: Objetos de interés detectados en dos distintos escenarios. La imagen de la izquierda reconoce 3 objetos en un lavabo. La imagen de la derecha detecta 4 objetos en una oficina.

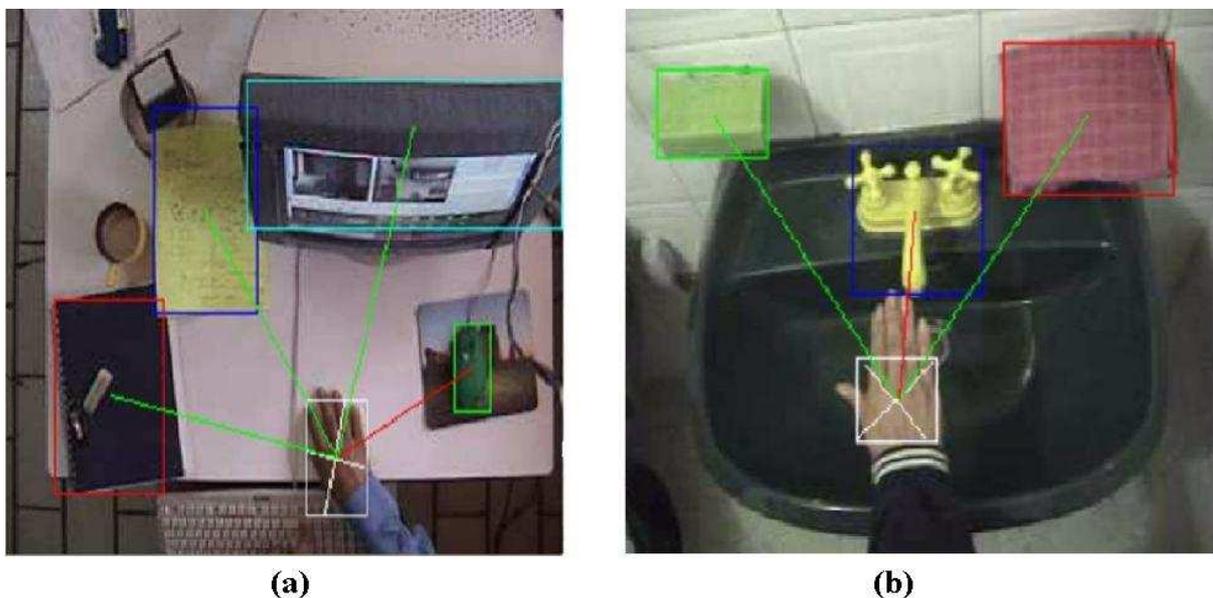


Figura 4.16: Imágenes que muestran la identificación de objetos de interés y su cercanía con la mano del usuario determinada por la distancia relativa entre los centroides. La línea con traza roja indica en cada escenario el objeto que se encuentra más cerca de la mano. Imagen (a) la mano se encuentra más cerca del *mouse*, imagen (b) el objeto más cerca de la mano es el grifo.

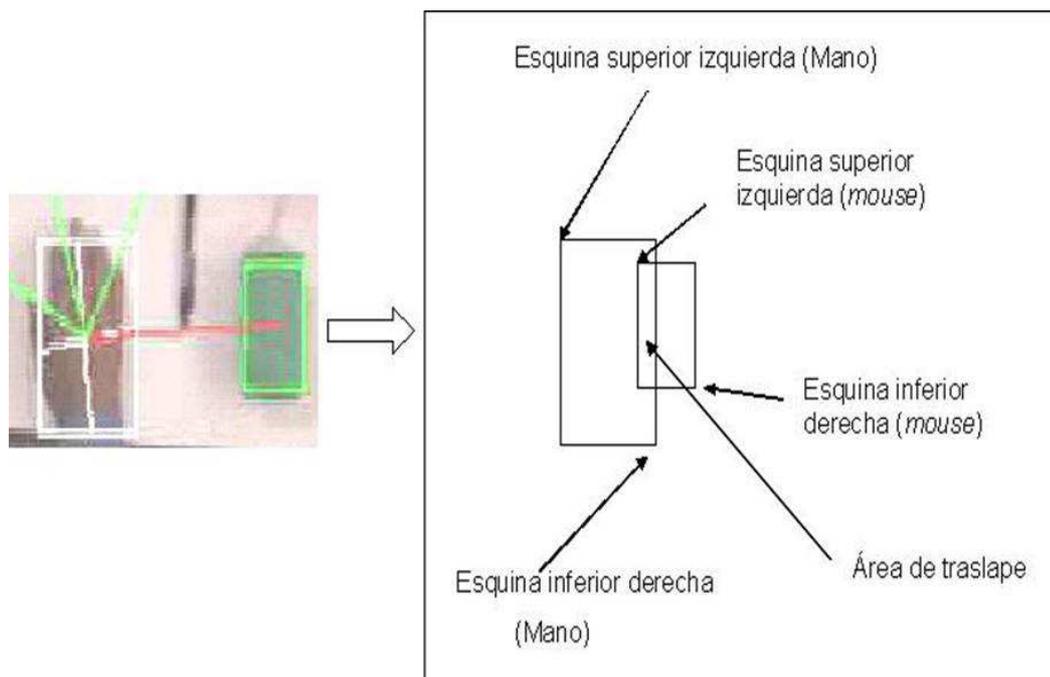


Figura 4.17: Imagen que ilustra el traslape entre la mano de una persona y un objeto. En la imagen mostrada a la izquierda la línea roja indica que la mano se acerca a uno de los objetos. La imagen derecha indica un traslape entre la mano de una persona y el *mouse*.

## 4.6. Reconocimiento de gestos utilizando contexto

La información contextual se maneja generalmente para apoyar el rendimiento de un sistema de reconocimiento automático de gestos [31, 76–78], tal como fue descrito en el Capítulo 2. En este trabajo, la información contextual que se utiliza para apoyar el proceso de reconocimiento está formada por el color que identifica a cada objeto y la distancia relativa entre cada objeto y la mano de la persona que va a manipularlos (ver Figura 4.16). A continuación se describen los pasos para integrar esta información al proceso de reconocimiento de gestos.

**Distancia relativa.** La distancia relativa entre los centroides de la mano y de los objetos se utiliza para indicar el contacto entre la persona y alguno de los objetos de interés. Por ejemplo, en la Figura 4.16, se ilustra que, la ventana que encierra a la mano (*bounding box*) se encuentra traslapando a la ventana que encierra al *mouse*, esto se deduce con los datos de las coordenadas (esquina superior izquierda y esquina inferior derecha) de las ventanas de ambos objetos. Se determina que existe contacto entre la mano del usuario y un objeto, cuando se verifica un traslape entre sus ventanas por un lapso de 5 cuadros (dato obtenido de manera experimental en los escenarios utilizados). Un ejemplo de este proceso se muestra en las Figuras 4.17 y 4.18. En el momento de definir el contacto, se marca tal condición como el estado inicial de un HMM, y se inicia la fase de seguimiento para obtener la trayectoria de la mano con fin de determinar el gesto que se está realizando.

Una vez que se inicia el seguimiento de la mano y el objeto en contacto, es necesario reconocer la actividad que se está realizando, considerando para ello información adicional relacionada con el objeto que se está manipulando. Por lo tanto, es necesario considerar una característica más a las definidas en la Sección 3.4, para el entrenamiento y evaluación de los HMMs.

**El contexto como parte de las características.** Incorporar la información de los objetos como parte

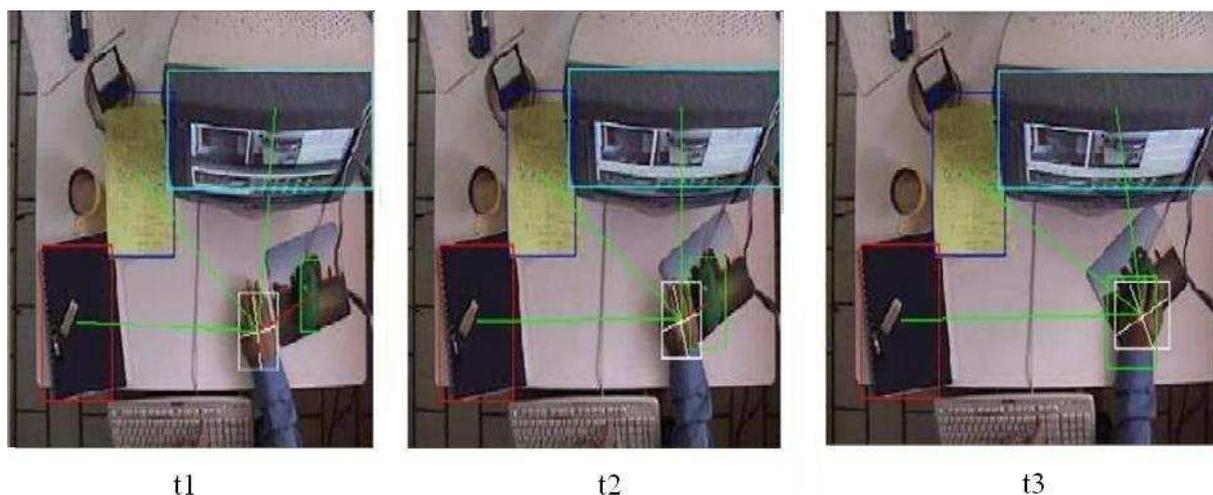


Figura 4.18: Secuencia de imágenes donde se muestran los instantes de tiempo en que se realiza el contacto con uno de los objetos en un ambiente de videoconferencia. El traslape entre las ventanas, tanto del objeto como de la mano indica el inicio del seguimiento.

del vector de características para entrenar y evaluar a los modelos ocultos de Markov, tiene la ventaja de que el movimiento de la mano y el objeto en contacto son aprendidos de manera simultánea durante un gesto. Al analizar la trayectoria de la mano se aplicó el conjunto reducido de características mostradas en la Ec. 4.1, sin embargo, después de realizar el proceso de reconocimiento de gestos (descrito en la Sección 4.3), las características que proporcionan el mayor porcentaje de reconocimiento son la combinación de  $\rho\phi$  (magnitud y orientación en coordenadas polares). Por lo tanto, el vector de características incluyendo la información de contexto es el siguiente:

$$F = \{(\rho_1, \phi_1, Objeto), \dots, (\rho_n, \phi_n, Objeto)\} \quad (4.23)$$

Las características de movimiento  $\rho\phi$ , fueron previamente discretizadas aplicando un proceso de cuantización vectorial a través de la técnica *k-medias* [38], con el fin de ser utilizadas como secuencias de observación durante el entrenamiento de los HMMs empleados. El tamaño del libro de códigos obtenido con el mayor porcentaje de reconocimiento es de 64 (ver Figura 4.13). Junto a los datos discretizados de la trayectoria de la mano, se agregan los datos correspondiente al color del objeto manipulado. Para identificar al objeto que se está manipulando, se aplica en la ventana de seguimiento de la mano, el algoritmo de *Intersección de Histogramas*, propuesto por Swain y Ballard [107]. Este algoritmo proporciona la identidad del objeto al comparar el histograma de la imagen (en este caso de la ventana de la mano), con los histogramas de modelos almacenados. Los pasos para identificar al objeto manipulado se describen a continuación:

1. Se crea un histograma con el valor de los píxeles dentro de la ventana de seguimiento de la mano, para esto se ignoran los píxeles de piel dentro de la ventana, creando una máscara o imagen binaria indicando qué píxeles se deben tomar en cuenta para calcular el histograma (se les asignan valores de 255).
2. Una vez obtenido el histograma de la ventana, se calcula la distancia más cercana, resultado al comparar el histograma obtenido con los histogramas previamente calculados (modelos). El valor de la distancia indica el objeto con el que se está interactuando. Estos valores se encuentran en el intervalo  $[0..N]$ , donde  $N$  es el número de objetos.

Una vez que se determina la identidad del objeto que está siendo manipulado, se procede a incorporarlo como parte de las características en la generación de la secuencia de observaciones.

## 4.7. Pruebas experimentales

En esta Sección se muestran las pruebas experimentales que se realizaron con el fin de seleccionar el modelo que mejor represente los gestos que se pretenden reconocer en los escenarios utilizados. El primer paso en este proceso, fue determinar el conjunto representativo de las características apropiadas para caracterizar los gestos. Inicialmente fueron seleccionadas 6 características y mediante un proceso exhaustivo de combinación se determinaron las 3 que ofrecieron los mejores resultados en el reconocimiento. El criterio utilizado para la selección de características fue el porcentaje en el reconocimiento de los gestos obtenido por los modelos ocultos de Markov (HMMs). Como resultado de este proceso, se seleccionaron las características que ofrecen mayor capacidad discriminante en el proceso de reconocimiento promedio de gestos. En esta prueba el procedimiento fue el siguiente: (i) se capturaron 100 secuencias de cada gesto realizados por una persona en un ambiente de oficina, (ii) se obtuvieron 5 repeticiones de 70 secuencias seleccionadas de forma aleatoria para entrenar el modelo, (iii) se obtuvieron 5 repeticiones de 30 secuencias elegidas de manera aleatoria para la evaluación. En la Tabla 4.2 se muestra el promedio de los resultados en estas pruebas. Se observa que el mayor porcentaje de reconocimiento alcanzado es de 97%, con modelos de 10 estados, 64 símbolos discretos de observación y dos características utilizadas ( $\rho$ ,  $\phi$ ). A partir de esta prueba se determina que las características seleccionadas son: la magnitud ( $\rho$ ) y orientación ( $\phi$ ) en coordenadas polares.

Tabla 4.2: Porcentaje de reconocimiento promedio correspondiente a 6 gestos realizados en un ambiente de oficina. Se muestran las características y número de estados utilizados.

Estados	Características						
	$\rho\phi v$	$\phi$	$\rho$	$v$	$\phi v$	$\rho\phi$	$\rho v$
5	87	96	66	50	90	90	69
6	87	96	63	51	91	89	70
7	88	96	72	51	92	89	72
8	86	90	70	60	92	89	70
9	84	91	69	79	93	95	80
10	82	88	68	78	92	<b>97</b>	70

En la siguiente prueba experimental se va a demostrar que el uso de información de contexto apoya el reconocimiento de gestos manipulativos. Para esta prueba, se consideraron las mismas condiciones manejadas con anterioridad (ambiente de oficina, mismos gestos, igual número de secuencias capturadas). Sin embargo, en esta ocasión se integra una característica adicional: el objeto con el que está interactuando la persona. Los resultados obtenidos en el proceso de reconocimiento de gestos manipulativos al integrar la información de contexto se muestran en la gráfica de la Figura 4.19. Se observa en este caso un porcentaje promedio de reconocimiento alcanzado de 98,57%, aplicando un HMM de 8 con estados y 64 símbolos de observación. Este porcentaje varía muy poco al incrementar el número de estados, por lo tanto, se pueden considerar estos datos como una elección apropiada para reconocer gestos manipulativos en otros escenarios. Se puede determinar a partir de los resultados obtenidos, que el uso de información de contexto incrementa la confiabilidad en el proceso de

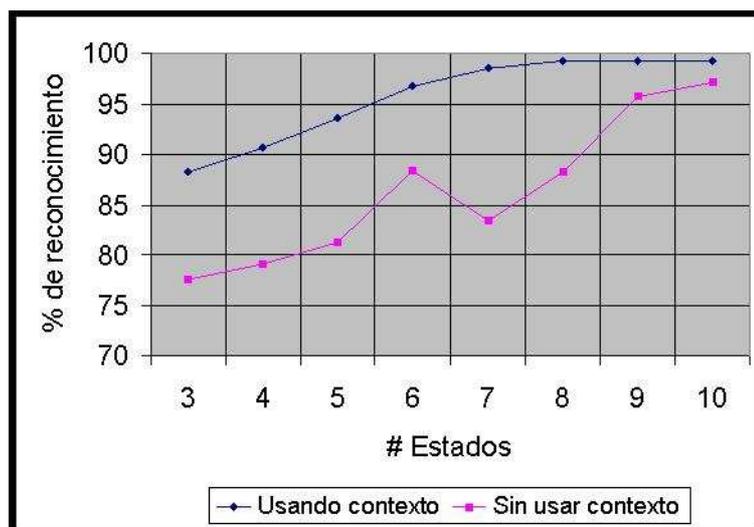


Figura 4.19: Figura que muestra el porcentaje de reconocimiento obtenido cuando se integra la información de contexto (objetos del escenario).

reconocimiento en este tipo de gestos. Las Tablas 4.4 y 4.3, muestran un enfoque comparativo en forma de matrices de confusión con los porcentajes de reconocimiento promedio obtenidos al evaluar el HMM seleccionado en un ambiente de oficina, considerando dos aspectos: (i) al utilizar información de contexto (Tabla 4.4) y (ii) sin utilizar información de contexto (Tabla 4.3).

Se puede observar una diferencia notable en el porcentaje de reconocimiento promedio cuando se aplica la información del entorno como parte del proceso de reconocimiento de gestos. Asimismo, se observa una diferencia entre el porcentaje de reconocimiento mostrado cuando no se utiliza información contextual (Tablas 4.3 y 4.2), esto se debe a que en un caso se utilizan modelos ocultos de Markov con un mayor número de estados.

Finalmente, se realizó una prueba experimental para demostrar que el uso de información de contexto permite reducir el número de datos utilizados. Para esta prueba, se emplearon solamente 50 secuencias de 6 diferentes gestos realizados en un lavabo. De estas secuencias, utilizamos 35 (seleccionadas de forma aleatoria y en 5 repeticiones) para el entrenamiento de los modelos y 15 (determinadas de forma aleatoria y en 5 repeticiones) para su evaluación. En la Tabla 4.5, se muestra a través de una matriz de confusión, el porcentaje de reconocimiento promedio obtenido al evaluar el modelo. Se observa que con un HMM de 8 estados y 64 símbolos de observación, se obtiene un porcentaje de reconocimiento promedio de 94%. El resultado obtenido en esta prueba se puede considerar satisfactorio dados los escasos datos de entrenamiento y de evaluación. Por lo tanto, se puede determinar que el uso de información de contexto permite obtener resultados satisfactorios aún con pocos datos utilizados durante el entrenamiento de los HMMs.

#### 4.7. Pruebas experimentales

Tabla 4.3: Matriz de confusión con resultados experimentales donde se muestra el porcentaje de reconocimiento de gestos obtenido en un ambiente de oficina sin el uso de contexto. El reconocimiento promedio alcanzado es de 88 %, aplicando un HMM de 8 estados.

S=8	Borrar	Escribir	Hojea	Mouse	Taza	Teléfono	% prom.
Borrar	22	8	0	0	0	0	<b>73</b>
Escribir	5	25	0	0	0	0	<b>83</b>
Hojea	0	0	30	0	0	0	<b>100</b>
Mouse	0	0	1	29	0	0	<b>87</b>
Taza	0	3	0	0	27	0	<b>90</b>
Teléfono	0	0	0	2	2	26	<b>86</b>

Tabla 4.4: Matriz de confusión con resultados experimentales donde se muestra el porcentaje de reconocimiento de gestos obtenido en un ambiente de oficina utilizando contexto. El reconocimiento promedio alcanzado es de 98 %, aplicando un HMM de 8 estados.

S=8	Borrar	Escribir	Hojea	Mouse	Taza	Teléfono	% prom.
Borrar	29	1	0	0	0	0	<b>97</b>
Escribir	1	29	0	0	0	0	<b>97</b>
Hojea	0	0	30	0	0	0	<b>100</b>
Mouse	0	0	0	29	0	1	<b>97</b>
Taza	0	1	0	0	29	0	<b>97</b>
Teléfono	0	0	0	0	0	100	<b>100</b>

Tabla 4.5: Matriz de confusión donde se muestra el porcentaje de reconocimiento de gestos obtenido en un escenario de lavabo al utilizar información de contexto. El reconocimiento promedio alcanzado es de 94 %.

S=8	Abrir/cerrar Grifo	Lavarse manos	Tomar jabón	Enjabonarse	Tomar toalla	Secarse manos	%
Abrir/cerrar Grifo	15	0	0	0	0	0	<b>100.00</b>
Lavarse manos	0	14	0	0	1	0	<b>99.33</b>
Tomar jabón	0	1	12	0	1	1	<b>80.00</b>
Enjabonarse	0	0	0	14	1	0	<b>93.33</b>
Tomar toalla	0	0	0	0	14	1	<b>93.33</b>
Secarse manos	0	0	0	0	0	15	<b>100.00</b>

## 4.8. Resumen del capítulo

En este capítulo se mostró el procedimiento para determinar la etapa I indicada en la Figura 1.1, es decir los pasos para seleccionar las características del modelo oculto de Markov que mejor represente los gestos que se pretenden reconocer en los escenarios utilizados. Se aplicó en la fase inicial de este proceso un modelo de color de piel novedoso (*RGY*), el cuál combinado con una técnica de análisis de movimiento sencilla como es la sustracción de imágenes, genera un esquema confiable para el reconocimiento de partes de una persona en ambientes reales. Asimismo, se manejó una variación al algoritmo de *CamShift* con el fin de permitir el seguimiento de partes de regiones, por ejemplo, seguir la mano de una persona sin tener que segmentar el brazo completo. Esto, abre la posibilidad de tener una técnica de seguimiento confiable en ambientes reales y con posibilidad de manejar oclusión. Se determinó aplicar los modelos ocultos de Markov (HMMs) para modelar los gestos realizados en diferentes escenarios, ya que estos modelos permiten representar de manera apropiada secuencias de datos temporales ante presencia de ruido, tales como los datos generados por la trayectoria de la mano al realizar una actividad y obtenidos a través de cámaras de vídeo. La selección de las características apropiadas es fundamental para el buen rendimiento de un sistema de reconocimiento de gestos. En este trabajo, la selección del conjunto representativo se determinó en base al rendimiento de los HMMs. Finalmente, se demostró que el uso de información de contexto (objetos de interés) como parte de las características, apoya el proceso de reconocer gestos manipulativos y permite disminuir el número de datos de entrenamiento. Los resultados experimentales obtenidos durante las diferentes etapas del proceso, indican que el modelo desarrollado es apropiado para ser utilizado en ambientes reales.

**Aportaciones del capítulo.** En este capítulo se realizan las siguientes contribuciones:

- Se muestra un método sencillo para realizar la detección de las partes de una persona en ambientes reales, utilizando la combinación de información basada en el color de piel y movimiento. Esta combinación solamente se aplica en la fase de detección de la mano de una persona.
- Se muestra un procedimiento de combinación de características exhaustivo, con el fin de seleccionar el conjunto representativo que permita discriminar los gestos realizados en un escenario. El criterio de selección se basó en el rendimiento de los modelos ocultos de Markov en el reconocimiento de los gestos modelados.
- Se realizó una modificación al algoritmo *CamShift* para permitir el seguimiento de partes de un mismo objeto, por ejemplo, seguir la mano de una persona sin tener que utilizar camisa de mangas largas. Esto resulta útil en diferentes escenarios, por ejemplo lavarse las manos sin tener que usar ropa especial. Esta modificación se realizó a través de dos aspectos: (a) la ventana de ajuste manejada por el algoritmo de *CamShift* no debe rebasar un tamaño fijado previamente y, (b) la posición donde el algoritmo de *CamShift* ubica la ventana es indicada por un filtro de Kalman.
- Finalmente, se desarrolló un método para incorporar la información de contexto como una característica adicional para el reconocimiento de gestos manipulativos. Tal información es integrada como parte de los símbolos de observación manejada por los modelos ocultos de Markov.

El objetivo que se persigue al desarrollar un sistema computacional confiable que permita reconocer el comportamiento humano en escenarios conocidos, es el diseño de sistemas automáticos

que tomen decisiones basados en esta información. Estos sistemas tienen una amplia gama de aplicaciones tales como: (1) seleccionar la mejor vista en un sistema de videoconferencias y, (2) apoyar a discapacitados a través de mensajes audibles.

## Capítulo 5

# Integrando información visual y teoría de decisiones

En este capítulo se describe el proceso para integrar la información visual procedente del módulo de reconocimiento de gestos utilizando información contextual (ver Capítulo 4), y la toma de decisiones a través de las redes de decisión dinámicas (RDDs). Se especifican en este capítulo los dos bloques que forman el Módulo II mostrado en la Figura 1.1 (Arquitectura del modelo propuesto). La sección 5.1, describe de manera general las características del enfoque propuesto. La descripción de la red de decisión dinámica para representar un problema de decisión de Markov parcialmente observable (POMDP) con un horizonte finito, se muestra en la Sección 5.2. En la Sección 5.3, se describe la toma de decisiones desde una perspectiva de dos etapas temporales analizadas. La especificación de los parámetros del modelo en cada uno de los escenarios utilizados se describe en la Sección 5.4. Finalmente, en la Sección 5.5 se realiza un resumen del capítulo.

### 5.1. Introducción

La finalidad del modelo propuesto es extender el proceso de reconocer la actividad humana observada al interactuar una persona con objetos en escenarios conocidos y tomar decisiones basado en un esquema de preferencias. Para ello, debe estimar el comportamiento de la persona al manipular objetos del entorno, y obtener una estrategia automatizada maximizando algún aspecto de utilidad o función objetivo. Algunos aspectos que rigen la selección del enfoque propuesto son los siguientes:

- (i) La obtención de información del escenario (a través de visión) está sujeta a ruido.
- (ii) Las variables que especifican el escenario son: la *posición de la mano* del usuario y el *objeto* en contacto con la misma, la relación entre estas variables determinan el comportamiento del usuario.
- (iii) El resultado de las acciones seleccionadas por el sistema es estocástico. Por ejemplo, en el escenario de apoyo a discapacitados, la reacción del usuario a una instrucción verbal no siempre es la correcta.

Bajo estas consideraciones, el sistema debe hacer inferencias basado en acciones observables, las cuales deben guiarse por sus creencias acerca de la situación (creencias acerca del comportamiento

del usuario, efectos de sus acciones). Por lo tanto, el modelo propuesto debe seleccionar acciones basado en el resultado de sus inferencias para cumplir los siguientes objetivos (enfocados al usuario):

- **Independencia de tareas.** El sistema intenta apoyar la independencia de las tareas del usuario, para esto, el sistema observa el comportamiento del usuario y no realiza ninguna acción cuando no sea necesario. Este objetivo se cumple en el escenario de apoyo a discapacitados, donde el sistema no selecciona instrucciones audibles cuando determina que el usuario sigue la secuencia correcta de pasos que lo llevan a completar una tarea.
- **Permitir un comportamiento natural del usuario en un escenario.** Una de las metas del sistema es apoyar al usuario al permitirle realizar sus actividades de manera natural y utilizar objetos del escenario como apoyo a tales actividades (escenario de videoconferencias).
- **Mantener el interés en el desarrollo de una tarea.** El sistema intenta mantener el interés del usuario al estar realizando una tarea, por ejemplo, si en el escenario de apoyo a discapacitados el usuario no sigue la secuencia de pasos correcta para completar una tarea, el sistema le proporciona indicaciones a través de instrucciones audibles.
- **Reaccionar al comportamiento observado.** El sistema debe reaccionar al comportamiento del usuario en diferentes escenarios con el fin de seleccionar la acción apropiada (escenario de videoconferencias y de apoyo a discapacitados)

Una técnica que permite manejar tales condiciones de operación son los procesos de decisión de Markov parcialmente observables (POMDPs) (ver Capítulo 3). En estos modelos, el estado no es conocido con certeza, por lo tanto, una política debe mapear ya sea estados de creencia (distribuciones sobre  $S$ ) o historias de *acción – observación*, con el fin de seleccionar las acciones apropiadas. Sin embargo, debido a los problemas que enfrentan los algoritmos que intentan obtener políticas óptimas en problemas de POMDPs de horizonte infinito, se recurre a soluciones aproximadas. En este trabajo, se aplican redes de decisión dinámicas (RDDs) para obtener una solución aproximada a problemas POMDPs de horizonte finito. Esta técnica permite integrar aspectos de incertidumbre y toma de decisiones en un mismo modelo, el grado de aproximación para la solución obtenida depende del número de etapas temporales analizadas a futuro. La obtención de la política  $\pi : S \mapsto A$ , la obtenemos mapeando las distribuciones probabilísticas de los estados hacia acciones al maximizar una función objetivo para la recompensa a largo plazo. La política obtenida se basa en la función objetivo más simple: **la recompensa total sobre un horizonte finito**. Tal recompensa, determina que en el tiempo  $t$ , el sistema debe optimizar su recompensa esperada en los próximos  $h$  pasos (ver Figura 5.1) de acuerdo con la siguiente expresión [53]:

$$E(S) = \left( \sum_{q=t}^{t+h} \gamma R_q \right) \quad (5.1)$$

donde  $E(S)$  es la recompensa total obtenida en el estado  $S$  al analizar  $h$  etapas de tiempo,  $R_q$  es la recompensa obtenida en la etapa  $q$ , y  $\gamma$  es un factor de descuento (su valor se considera en el intervalo  $0 - 1$ ).

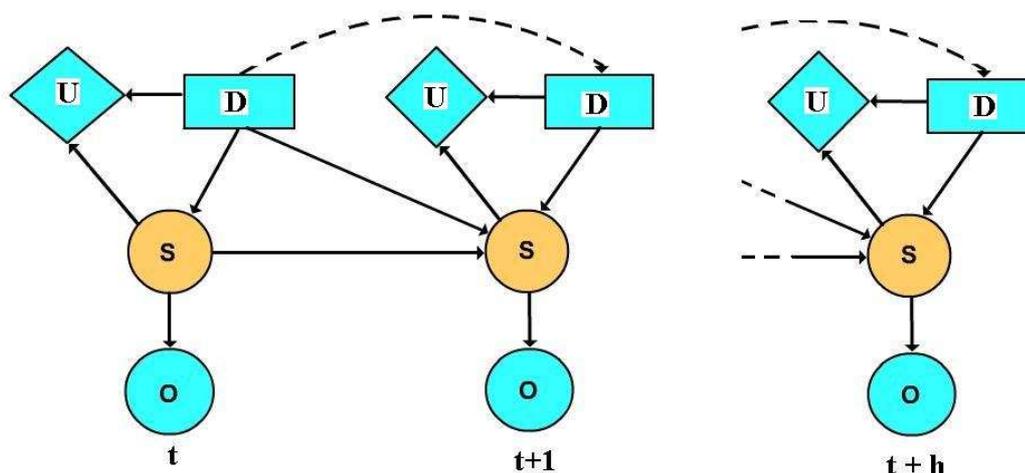


Figura 5.1: Imagen que ilustra  $h$  etapas temporales en un POMDP representado como una red de decisión dinámica. Las acciones (D) inducen transiciones entre estados (S). Una función de utilidad (U), determina la preferencia de elegir una alternativa de acción.

## 5.2. Representación de la RDD

La Figura<sup>1</sup> 5.1 muestra la representación de un POMDP de horizonte finito a través de una red de decisión dinámica, donde todos los estados  $s \in S$  han sido mapeados a nodos aleatorios  $S$ , todas las acciones  $a \in A$  a nodos de decisión  $D$ , y todas las recompensas  $R$ , a nodos de valor o de utilidad  $U$ . Los nodos de utilidad expresan la preferencia de seleccionar la acción  $a$  en el estado  $s$  y tiempo  $t$ . El modelo desarrollado en este trabajo utiliza una red de decisión dinámica para seleccionar la mejor acción basada en los gestos realizados por un usuario y observados por cámaras de vídeo. Aunque la toma de decisiones basada en información visual del comportamiento humano se ha utilizado en trabajos recientes [11, 41, 49, 70], ninguno de ellos ha incorporado información contextual para apoyar la etapa reconocimiento de gestos, y tampoco se ha utilizado una RDD como un método para tomar decisiones. Tal vez el poco uso de las RDDs como un enfoque para la toma de decisiones se debe a su reciente aparición [45] como un mecanismo para tomar decisiones. Sin embargo, los resultados obtenidos por algunos investigadores ([57], [80]), en sistemas implementados para tomar decisiones dinámicas, alientan la incorporación de esta técnica en otros escenarios, tales como los presentados en esta tesis.

El uso de una RDD nos permite modelar la actividad humana y a la vez tomar acciones basada en preferencias. Es decir, la red de decisión dinámica permite integrar el comportamiento de una persona (representado por los nodos de observación y de estados, ver Figura 5.1), y a la vez tomar acciones óptimas (indicadas por los nodos de decisión y de utilidad, ver Figura 5.1) basada en un esquema de máxima utilidad esperada.

<sup>1</sup>En esta tesis se va a emplear la siguiente notación gráfica para una red de decisión dinámica: a) los nodos de decisión se van a representar con rectángulos, b) los nodos de utilidad van a ser representados por rombos o diamantes y, c) los nodos aleatorios y de observación se van a ilustrar por óvalos. Los nodos de utilidad no tienen nodos hijos, las flechas indican el flujo de la información entre los nodos.

### 5.3. Etapas del modelo

El modelo presentado en este trabajo se basa en una RDD para implementar la toma de decisiones en sistemas automatizados que apoyen o asistan a personas al desempeñar sus actividades, tales como en un sistema de video conferencia [75] o de apoyo a discapacitados [74]. El objetivo es seleccionar la mejor opción determinada por un esquema de preferencias al operar el sistema en escenarios conocidos. Esta selección se basa en el enfoque de máxima utilidad esperada (aplicando la expresión 5.1), considerando los objetivos del modelo y del usuario. Para esto, se consideran los posibles resultados de cada acción a través de futuras etapas temporales, ponderados por la utilidad de cada respuesta y la creencia acerca del gesto más probable realizado por el usuario. La estructura del modelo de red utilizada toma acciones óptimas basada en el análisis a futuro de una secuencia de etapas temporales (ver Figura 5.1). La toma de decisiones se basa en el siguiente procedimiento:

1. Se reconoce el gesto más probable en el tiempo  $t$  (ver Capítulo 4).
2. Se estiman los siguientes gestos a través de una secuencia de etapas analizadas en un tiempo finito ( $t + h$ ).
3. Se selecciona la acción óptima (la acción con la máxima utilidad esperada) obtenida en esta serie de etapas.
4. Se observa el efecto de la acción en el comportamiento del usuario.
5. Termina el proceso si la actividad del usuario finaliza, de otra manera retorna al paso 1.

Estos pasos, son realizados por una RDD como la mostrada en la Figura 5.1, sin embargo para fines de análisis se pueden considerar solamente dos etapas de tiempo, tal como se indica en el procedimiento ilustrado en la Figura 5.2. Las etapas especificadas por este procedimiento se describen enseguida.

**Etapas 1.** La etapa 1 representa la creencia del sistema con respecto al estado actual del usuario, en esta etapa se define su comportamiento. En este trabajo, el comportamiento del usuario en escenarios conocidos se determina aplicando los modelos ocultos de Markov (HMMs) [96], los cuales proporcionan las observaciones  $O_1, O_2, \dots, O_n$ , o evidencia a la red de decisión dinámica (nodo **O** en la Figura 5.1). La información proporcionada por los HMMs forman la distribución de probabilidades asignadas a los estados del sistema (comportamiento del usuario). La incorporación del contexto en el reconocimiento de gestos disminuye la incertidumbre relacionada con la creencia hacia estos estados  $b(s)$ . Una vez que se determina el comportamiento del usuario el modelo debe decidir cuál es la mejor acción que debe tomar, para apoyar esta decisión se utilizan recompensas. El modelo propuesto asigna una recompensa positiva (+3) a la acción que apoye al usuario a alcanzar sus objetivos (por ejemplo: avanzar en la secuencia de pasos correctas para completar una tarea en un escenario de apoyo a discapacitados), asimismo, asigna una penalización (recompensa negativa de  $-3$ ) a la acción que nos aleje de este objetivo. En el escenario de apoyo a discapacitados se utiliza un segundo valor de penalización de  $-6$  asignada a la acción de *Solicitar Ayuda*, con el fin de expresar la menor preferencia del sistema hacia esta acción. Para mantener un control de la información manejada, el modelo considera el efecto de las acciones tomadas en la etapa actual ( $A_t$ ) y su efecto tanto en el estado actual ( $S_t$ ), como en el siguiente ( $S_{t+1}$ ) (enlaces que se observan partiendo de los nodos de decisión y entrando a los estados en la Figura 5.1). Considerar el efecto de las acciones en el estado actual

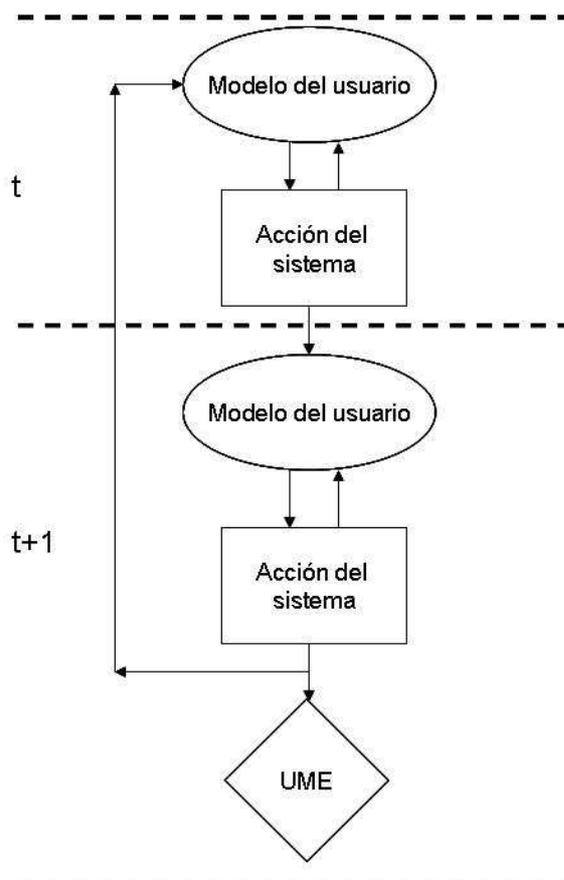


Figura 5.2: Procedimiento utilizado para la selección de la acción óptima basada en una red de decisión dinámica (RDD). La imagen muestra el ciclo para tomar una decisión basándose en la estructura de la red utilizada. En el tiempo  $t$  se observa el comportamiento del usuario y se determina el gesto más probable, esto forma el modelo del usuario. El sistema toma una acción basado en esta información de acuerdo a los objetivos del modelo y al conocimiento del dominio. En el tiempo  $t + 1$ , se estima el siguiente gesto más probable de acuerdo a los valores de probabilidad condicional y probabilidad *a priori*, considerando el efecto de la acción realizada en  $t$  y de acuerdo con los objetivos del modelo se obtiene la acción óptima (basada en la utilidad máxima esperada (UME)).

y siguiente del sistema, nos proporciona una manera de determinar, basado en más información, la dinámica del sistema (matrices de transición). Esto incorpora una mayor confiabilidad de representar el comportamiento del usuario en etapas futuras, lo cual permite utilizar sencillos esquemas de preferencias, a diferencia de otros trabajos [11, 41] que emplean modelos más complicados para la toma de decisiones. El método utilizado para determinar la política se basa en mapear estados de creencia ( $b(s)$ ) a acciones, el cual es apropiado considerando lo expuesto.

**Etapa 2.** Esta etapa representa el comportamiento del usuario en  $t + 1$  como consecuencia de la acción realizada por el sistema en la etapa anterior ( $t$ ) (ver Figura 5.3). Se asume que la mayor influencia en la acción del sistema ocurre en esta etapa. Por ejemplo, en una aplicación de apoyo a personas con problemas de memoria, las acciones tomadas por el sistema pueden ser un conjunto de mensajes audibles que guíen a la persona para que realice los pasos necesarios en completar una tarea. En un escenario de videoconferencias, las acciones consisten en seleccionar la mejor vista del proceso de exposición para mostrárselas a la audiencia en base a los gestos realizados por el expositor. La acción se selecciona en base al comportamiento observado del usuario y a un esquema de preferencias indicadas por el sistema (por el momento se determina de manera subjetiva basado en experiencias personales en el caso del escenario de videoconferencias y en trabajos similares en el caso del escenario de apoyo a discapacitados). Las probabilidades de transición describen los cambios estocásticos de estado inducidos por cada acción y definen la dinámica del ambiente, y constituyen la base de la asunción Markoviana ( $P : S \times A \times S \rightarrow [0, 1], Pr(S_{t+1}|S_t, A_t)$ ). En esta etapa se consideran los objetivos del modelo y del usuario con el fin de determinar de manera correcta el comportamiento esperado del usuario como consecuencia de la acción realizada en la etapa 1.

La base de un sistema de redes de decisión dinámicas (RDDs) son las preferencias hacia ciertas acciones considerando el estado más probable. Estas preferencias son representadas de manera cuantitativa a través de utilidades. Es decir, un número real representa las preferencias del sistema a tomar ciertas acciones en base a estados probables. Las creencias del sistema hacia estos estados se expresan en forma de probabilidades (equivale a la tabla de probabilidad condicional asociada a un nodo aleatorio en una red Bayesiana (ver Figura 3.2)) en nuestro modelo esta información es proporcionada por modelos ocultos de Markov. Las probabilidades de los estados son actualizadas utilizando algoritmos de inferencia bayesiana [46]. El sistema selecciona la acción que le proporciona la máxima utilidad esperada (MUE) al aplicar la Ec. 5.1 a un determinado número de etapas temporales. La selección de la acción debe ser congruente con los aspectos considerados en la etapa 1: i) las alternativas de acción que el sistema prefiere usar, ii) la relevancia de la acción escogida por el sistema, y iii) la coherencia de la acción del sistema en respuesta al comportamiento del usuario. Por ejemplo, si en un ambiente de videoconferencias se observa que el expositor está *hojeando un libro*, entonces el sistema deberá *mostrar el libro* a la audiencia.

Las Figuras 5.3 y 5.4 ilustran la evolución de las etapas mencionadas en los escenarios utilizados en este trabajo.

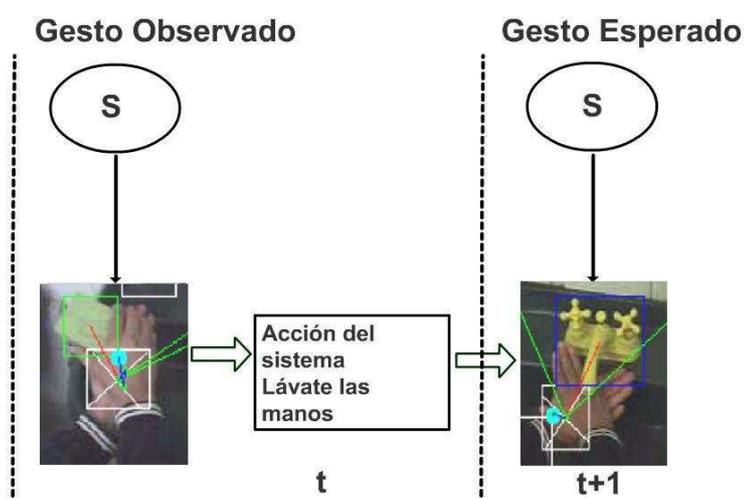


Figura 5.3: Imagen que muestra las etapas de tiempo que forman el ciclo de decisión utilizado en nuestro modelo, aplicado para apoyar la terminación de una tarea. En la imagen de la izquierda se observa el comportamiento actual del usuario: *enjaponándose las manos*. En la imagen central se observa la acción (instrucción audible) tomada por el sistema, la cual además de proporcionar información en el momento actual, intenta afectar la transición al siguiente estado. La imagen de la derecha ilustra el comportamiento esperado por el usuario en  $t + 1$  al realizarse la acción indicada en  $t$ .

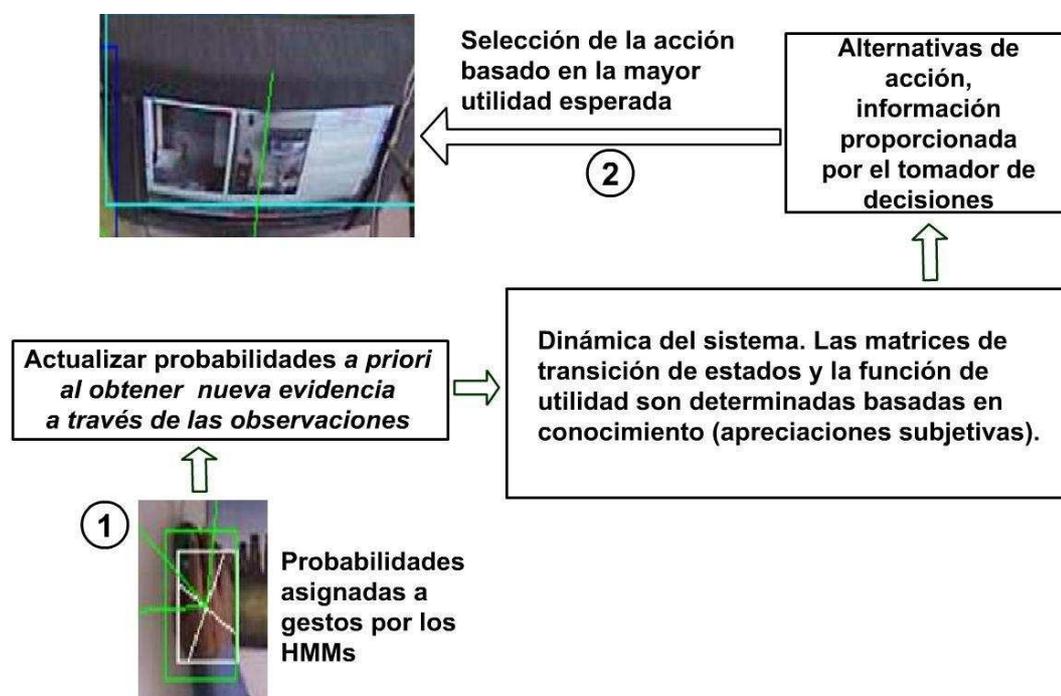


Figura 5.4: Imagen que ilustra el proceso para seleccionar la mejor vista que el sistema debe mostrar a la audiencia en un escenario de videoconferencias. En la etapa 1, el sistema observa, analiza y reconoce el comportamiento del expositor (*usando el mouse*). Posteriormente (etapa 2) en base a la dinámica especificada por el sistema y el comportamiento humano, se selecciona la alternativa óptima (*mostrar la pantalla*).

### 5.4. Especificación del modelo

Un modelo basado en teoría de decisiones debe ser flexible en su comportamiento, debe ajustar de manera automática sus acciones con el fin de maximizar sus objetivos al actualizar sus creencias. Para complementar esta flexibilidad, el modelo desarrollado permite sencillas modificaciones al aplicarse en diferentes escenarios. Tales modificaciones incluyen los principales parámetros del sistema: probabilidad *a priori*, probabilidades condicionales y utilidades. El cambio más significativo, ocurre en el nodo de las observaciones, ya que prácticamente decide el uso del sistema en distintos escenarios. Cambios menores ocurren en los nodos de decisión y de utilidad. Sin embargo, podemos considerar que la estructura de la RDD utilizada es casi la misma para distintos escenarios. Una vez realizados estos cambios, el sistema funciona de manera automática, la única intervención humana es para detener la operación del mismo. Estas variaciones las vamos a exponer para cada uno de los escenarios manejados en este trabajo. El primer escenario consiste en un ambiente de videoconferencias, donde el sistema además de apoyar la actividad del expositor (permitiéndole un comportamiento natural y el uso de material didáctico), toma decisiones consistentes en seleccionar la mejor vista de la exposición para mostrarla a la audiencia, basándose en el comportamiento del expositor. El segundo escenario es un ambiente de apoyo a discapacitados, donde el sistema debe guiar a una persona a través de mensajes audibles a seguir los pasos necesarios para completar una tarea, en este trabajo: *asearse las manos*. En ambos escenarios se tienen que cumplir algunos compromisos relacionados con los objetivos del modelo, estos van a ser abordados en el siguiente capítulo.

#### 5.4.1. Descripción de escenarios

El sistema desarrollado permite tomar decisiones basándose en la observación visual de actividades realizadas por una persona al manipular objetos del entorno. Este esquema cumple con las expectativas de una amplia variedad de aplicaciones, tales como: videoconferencias [75], sistemas de seguridad y vigilancia, espacios inteligentes y apoyo a discapacitados [11, 74], entre otras. En este trabajo se aplica el sistema en dos escenarios novedosos: videoconferencias y apoyo a discapacitados. A continuación se proporciona una descripción de cada escenario.

##### Escenario A: Videoconferencias

En este escenario una persona expone un tema a la audiencia. El objetivo del modelo en este escenario es seleccionar la mejor vista que debe ser mostrada a la audiencia, a la vez, se le permite al expositor comportarse de forma natural, asumiendo en todo momento que la audiencia tiene una vista de los aspectos relevantes relacionados con el desarrollo de la exposición. El expositor puede utilizar recursos didácticos para apoyar su actividad, tales como: *hojas para escribir* (alguna expresión matemática o frase), *libro* (para mostrar alguna figura o página específica), y la *pantalla de la computadora* (para mostrar en todo momento lo que se está explicando). La Figura 5.5, muestra la vista superior del escenario observado por una cámara de vídeo, donde se aprecian los recursos didácticos mencionados. La RDD que describe a este escenario presenta una característica importante, las acciones seleccionadas por el sistema no afectan directamente el comportamiento del usuario. Esta situación se ilustra en la red mostrada en la Figura B.1, donde no existen enlaces con trayectorias de los nodos de decisión hacia los nodos de estados. Podemos considerar a esta red un caso especial de problema POMDP.



Figura 5.5: Imagen que muestra la vista superior del escenario de videoconferencias donde se observan los objetos didácticos que el expositor puede utilizar para apoyarse en la exposición: libro (de pasta azul), hoja para escribir (en color amarillo), *mouse* y la pantalla de la computadora.

En este escenario, el modelo de RDD utilizado debe proporcionar a través de la especificación de sus parámetros un compromiso entre sus objetivos, de tal manera que la información proporcionada a la audiencia sea consistente con la actividad del conferencista (ver Figuras 5.6 y 5.7). Para cumplir con estos compromisos los parámetros de la RDD son especificados de la siguiente manera.

- **El nodo de utilidad.** El nodo de utilidad está representado por una tabla de utilidad, la cual aunque menos descriptiva que una función de utilidad permite simplificar los cálculos. Este nodo se utiliza para determinar las preferencias del sistema hacia las acciones basado en el comportamiento más probable del expositor. Para esto se maneja un valor positivo<sup>2</sup> (+3) para indicar las preferencias hacia ciertos comportamientos, y un valor negativo (-3) en caso contrario.
- **Nodo de decisión.** Especifica las acciones del sistema. En este escenario, las acciones corresponden a las diferentes vistas que el sistema debe mostrar a la audiencia, basadas en la creencia del sistema  $b(s)$  hacia los gestos realizados por el expositor. El conjunto de acciones que puede seleccionar el sistema en este escenario son  $A = (\text{mostrar el rostro del expositor}, \text{mostrar la pantalla de la computadora}, \text{mostrar una hoja para escribir/borrar y mostrar un libro})$ .
- **Nodo de estados ( $S$ ).** En nuestro modelo, el nodo de estados ( $S$ ) es la variable aleatoria que representa el comportamiento del usuario y está formado por el conjunto de gestos que el expositor realiza (modelados por HMMs). En todo momento, el estado de este nodo se determina por una distribución de probabilidades hacia los posibles gestos del expositor. En este escenario, el conjunto de valores que forman a esta variables son  $S = (\text{usando la computadora},$

---

<sup>2</sup>Generalmente, la elección de la escala empleada en los nodos de utilidad es arbitraria [68], se manejan valores positivos para indicar las preferencias (recompensas) hacia ciertas acciones y valores negativos en caso contrario (costos), estos valores pueden cambiar sin afectar el orden de las preferencias. En este trabajo, se manejaron diferentes valores: [-1, +1], [0, +1], y [-6, -3, +3], los cuales solamente modificaron el valor de la utilidad obtenida sin afectar la selección de la mejor acción.

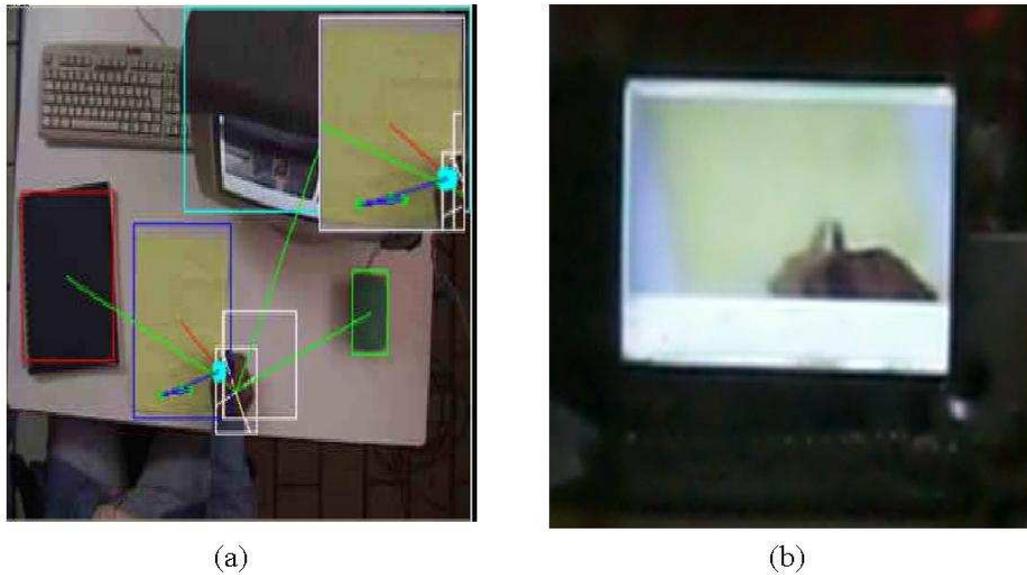


Figura 5.6: Imágenes donde se muestra el aspecto de consistencia en la información manejada por el sistema. En la imagen (a) el expositor se encuentra *escribiendo en una hoja de papel*, por lo que el modelo selecciona la acción que le ofrece la máxima utilidad esperada, en este caso: *mostrar la hoja de papel* en la pantalla de la audiencia (imagen (b)).

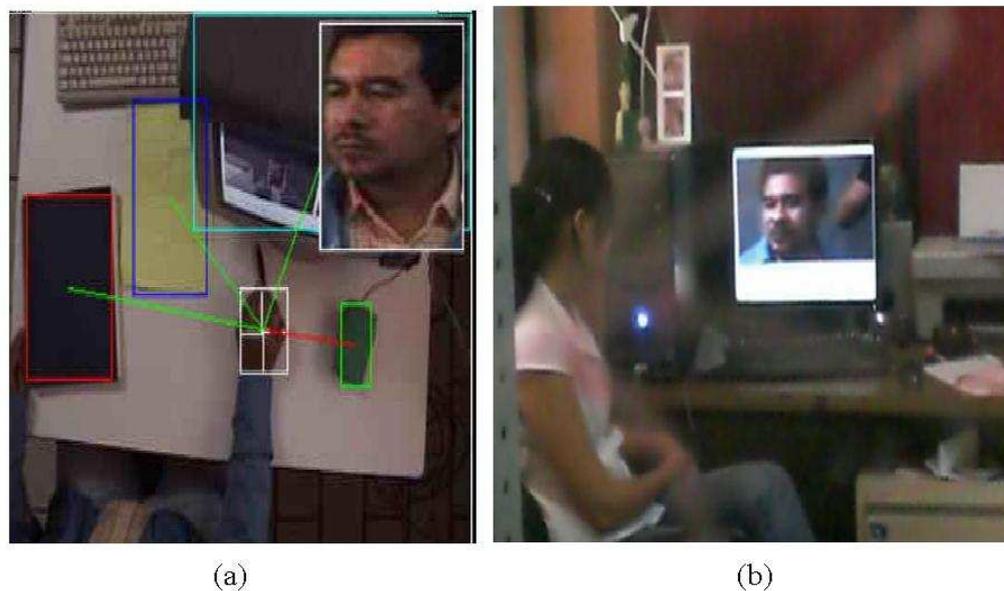


Figura 5.7: Imágenes que muestran aspectos de consistencia en la operación del sistema. En la imagen (a) se observa que el expositor no está interactuando con objetos de interés, por lo que el sistema al evaluar la dinámica del ambiente asume que está hablando. Por lo tanto, la selección de la acción que proporciona la máxima utilidad esperada es: *mostrar el rostro del expositor*, esta acción se visualiza en la pantalla de la audiencia (imagen (b)).

*escribiendo/borrando en una hoja, hojeando un libro y hablando*<sup>3</sup>). Al incorporar un mayor número de gestos para ser reconocidos, estos deben ser previamente modelados utilizando los modelos ocultos de Markov.

- **Nodo de observación** ( $O$ ). Este nodo representa la evidencia del sistema al mundo real, o información del sensor. En este escenario, esta función de observación está representada por los modelos ocultos de Markov (HMMs) [95], los cuales determinan el gesto más probable del expositor y actualizan la distribución de probabilidades de la variables de estados ( $S$ ).
- **Dinámica del sistema**. La dinámica del sistema se especifica por la matriz de transición, la cual determina la evolución temporal del ambiente bajo observación (actividad del expositor). Las probabilidades en esta matriz describen los cambios estocásticos del comportamiento del expositor. En este modelo, las probabilidades de transición se determinan de acuerdo a la suposición Markoviana  $Pr(s_{t+1}|s_t)$ , estos valores son determinados mediante apreciación subjetiva a través de ejemplos observados. Por el momento, esta información se proporciona de manera manual en la RDD, sin embargo se pretende manejar como una mejora a futuro incorporar técnicas de aprendizaje para aprender esta información.

En el Anexo B, se describen la obtención de los parámetros que especifican a la RDD utilizada.

### Escenario B: Apoyo a personas para completar tareas

En este escenario, al igual que el anterior el objetivo del sistema consiste en seleccionar la acción apropiada con base en el comportamiento de una persona al manipular objetos del entorno. En este caso, las acciones realizadas por el sistema se enfocan en obtener una estrategia para guiar a una persona con alguna discapacidad (problema de memoria o problema para coordinar ideas) a terminar una tarea. Las acciones en este escenario son un conjunto de instrucciones audibles que guían a una persona (usuario), a realizar una secuencia ordenada de pasos, necesarios para terminar una tarea. Estas tareas son determinadas por conocimiento experto y serán descritas en el capítulo siguiente. El escenario utilizado es un lavabo con los objetos necesarios (*grifo, toalla, jabón*) que permitan realizar la tarea específica: *asearse las manos*. En base a este escenario, se muestra en la Figura 5.8 la secuencia gradual y ordenada de los pasos que debe realizar el usuario para terminar la tarea mencionada. El sistema debe apoyar al usuario a ir de manera progresiva de un paso de la tarea a otro para que alcance su objetivo, cuando observa que está realizando una tarea que lo aleja del objetivo. Por ejemplo, en la Figura 5.8, si después de observar al usuario *enjabonarse las manos*, el sistema cree que el usuario pretende *secarse la manos*, entonces una instrucción audible (*lávate las manos*) debe especificar al usuario el paso de tarea que debe realizar. De otra manera, si el sistema cree que se están realizando los pasos de tareas en el orden apropiado, entonces no se deben hacer indicaciones al usuario. A diferencia de la red que describe al escenario anterior, en este caso las acciones seleccionadas por el sistema si afectan el comportamiento del usuario (ver Figura B.4).

---

<sup>3</sup>Esta acción es la alternativa seleccionada por omisión.

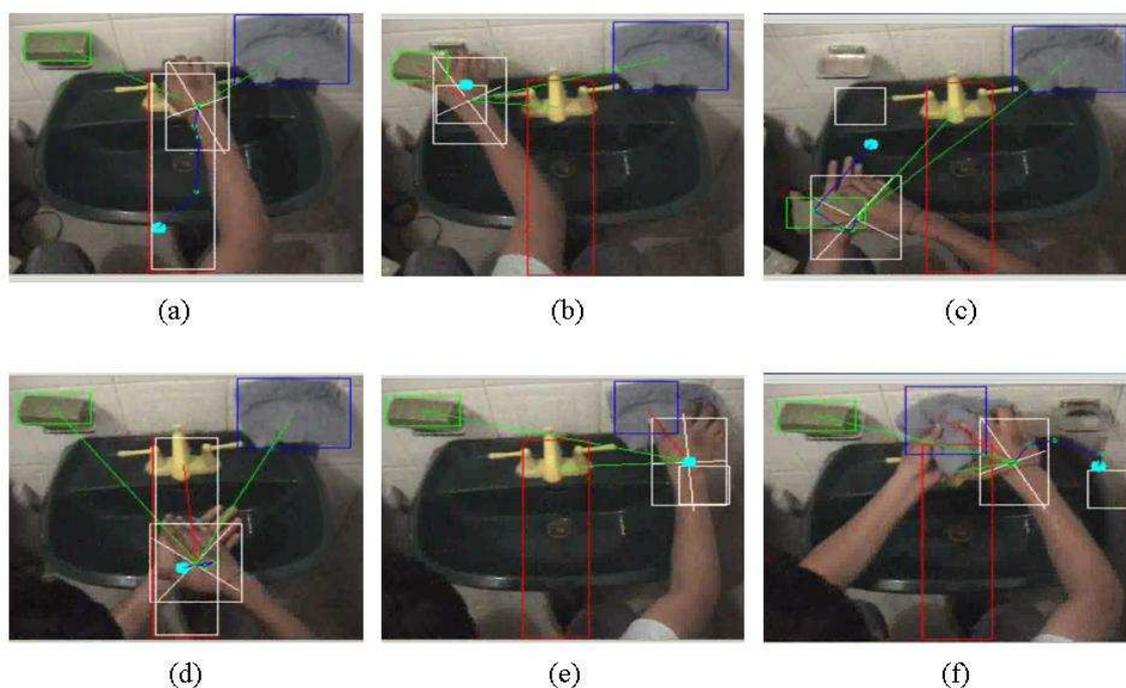


Figura 5.8: Imagen mostrando la secuencia de pasos que sigue una persona para completar la tarea: *asearse las manos*. En la imagen (a) se observa a la persona *abriendo el grifo*, en (b) *tomando el jabón*, en la imagen (c) la persona se está *enjaponando las manos*, en la imagen (d) la persona se está *lavando las manos* y en (e) se observa la mano de la persona tomar la toalla para *secarse las manos* (f).

Para poder cumplir con estos objetivos, el sistema considera el análisis de dos etapas de tiempo a la vez ( $t$  y  $t + 1$ ), con la siguiente especificación de la RDD:

- **Nodo de utilidad.** Las utilidades del sistema definen las preferencias hacia los distintos mensajes que el sistema debe seleccionar. Estas preferencias se representan al igual que el escenario anterior por una tabla de utilidades. Las preferencias hacia la acción apropiada se indican a través de una recompensa (+3), de otra manera el rechazo a una acción se indica por una penalización (-3), además en este escenario se utiliza una penalización con valor de -6 para indicar una preferencia mínima hacia una acción, en este caso *solicitar asistencia humana*.
- **Nodo de decisión.** Especifica el conjunto de mensajes que el sistema considera dentro de sus posibles alternativas de decisión y son los siguientes  $A = (\text{abre el grifo, mójate las manos, enjabónate las manos, lávate las manos, sécate las manos, cierra el grifo, acción nula y solicitar asistencia})$ . Los mensajes son seleccionados solamente cuando el sistema observa que en el tiempo  $t + 1$  el gesto esperado (ver Figura 5.3) no es el correcto de acuerdo al grafo de tareas definido por el modelo experto (ver capítulo siguiente). La *Acción nula*, indica que los pasos se están realizando en el orden correcto y por consiguiente no resulta necesario realizar alguna acción, esta acción permite cumplir con el objetivo de independencia de tareas. El mensaje: *solicitar asistencia*, especifica cuando el sistema no es capaz de guiar a una persona a completar una tarea (por el momento no se aplica).
- **Estados del sistema.** Los estados del sistema se representan en la red por la variable aleatoria  $S$ , la cual especifica el número de gestos que determinan el comportamiento del usuario. En

este escenario, el valor de esta variable está formada por los siguientes gestos:  $S = (\text{abriendo/cerrando el grifo, mojándose las manos, enjabonándose las manos, lavándose las manos y secándose las manos})$ . El comportamiento del usuario se determina por una distribución de probabilidades, las cuales representan la creencia del sistema ( $b(s)$ ) hacia los diferentes gestos. La especificación de esta información se realiza de manera manual en la RDD utilizada.

- **Nodo de observación (O).** Al igual que la red definida para el escenario anterior, la información de los nodos de observación es proporcionada por gestos modelados utilizando modelos ocultos de Markov. En este caso, los gestos modelados son los indicados en los estados del sistema.

**Dinámica del sistema.** La evolución del sistema se define por la matriz de transición de estados. En este escenario, se necesita llevar un registro de la secuencia de tareas que el usuario está realizando para saber si está progresando hacia el objetivo, o se aleja del mismo. Para llevar un control de este registro, a diferencia de otros trabajos [11, 70], se asume en este trabajo que es suficiente mantener la historia de la secuencia de dos acciones evaluadas por la siguiente expresión:  $Pr(s_{t+1}|s_t, a_t, a_{t+1})$  y de un grafo de tareas. Se considera que, si en el tiempo actual  $t$  la creencia del sistema se afecta por la acción actual ( $a_t$ ), esto trae como consecuencia que su valor de creencia ( $Pr(s_t|a_t)$ ) aumente o disminuya. En este sentido la acción ( $a_t$ ), aumenta la creencia hacia un gesto determinado, este efecto se propaga al siguiente estado aumentando la probabilidad de creencia hacia el gesto que sigue en secuencia (*enjabonándose las manos*  $\rightarrow$  *lavándose las manos*). El resultado de este proceso, es la especificación de la matriz de probabilidades condicionales asignadas de manera inicial a las nodos de estados que forman las etapas temporales analizadas en la red. A la vez, esta información se apoya con un grafo de tareas descrito por el modelo experto para indicar las posibles tareas en  $t + 1$ , dependiendo de las tareas estimadas en  $t$ . Por el momento, los datos para las matrices de transición son determinados de manera subjetiva a través de ejemplos al observar a un grupo de 10 personas realizar los diferentes pasos para completar la tarea de asearse las manos. Sin embargo, esta información se piensa integrar posteriormente al sistema aplicando técnicas de aprendizaje.

## 5.5. Resumen del capítulo

En este capítulo, se muestra el enfoque utilizado para integrar el comportamiento humano observado a través de información visual y la toma de decisiones dinámicas en ambientes reales basada en tal información visual. El enfoque presentado utiliza redes de decisión dinámicas como una alternativa para aproximar soluciones a problemas de POMDPs de horizonte finito. las redes de decisión dinámicas, son un enfoque reciente que permiten integrar aspectos de incertidumbre, manejo de múltiples objetivos y la toma de decisiones en un mismo modelo. Estas características hacen a esta técnica atractiva para un gran número de aplicaciones en ambientes reales tales como: videoconferencias y apoyo a discapacitados. Se presenta la selección de la acción óptima a través de una red analizada en avance como una secuencia de nodos de decisión, la cual puede ser analizada bajo una perspectiva de dos etapas temporales. Se describe la especificación de la red de decisión dinámica utilizada en dos escenarios diferentes. El escenario de videoconferencias, se puede considerar como un caso especial de problemas POMDPs en el cual la selección de la acción no afecta el comportamiento del usuario, mientras que las características de la aplicación de apoyo a discapacitados sugieren que la acción seleccionada debe afectar el comportamiento del usuario. Estas situaciones se reflejan en las redes que representan a cada escenario. Aunque por el momento, algunos parámetros del sistema (matrices de transición) son determinados de forma manual, mientras que otros (nodos de observación, probabili-

## 5.5. Resumen del capítulo

---

dades *a priori*) son aprendidos, se considera que en general la especificación del modelo es sencilla y susceptible de utilizarse en diferentes escenarios con ligeras modificaciones.

# Capítulo 6

## Evaluación del modelo

En este capítulo se describen las pruebas experimentales realizadas para evaluar el modelo desarrollado. La Sección 6.1, inicia con una introducción donde se resaltan los objetivos de un sistema para la toma de decisiones desde un enfoque de redes de decisión dinámicas. Posteriormente en la Sección 6.2, se describen los criterios para la evaluación del modelo en dos etapas: (i) análisis cuantitativo en base al tiempo de respuesta y selección de la acción óptima, y (ii) análisis cuantitativo en base al rendimiento del modelo percibido por participantes en dos escenarios distintos al comparar el modelo contra un humano. En la Sección 6.3 se describe la plataforma de implementación del sistema, y finalmente en la Sección 6.4 se presenta un resumen del capítulo.

### 6.1. Introducción

El modelo propuesto en este trabajo, realiza la selección de la mejor acción en el tiempo actual ( $t$ ) a través de analizar una serie de etapas temporales a futuro ( $t + 1, t + 2, \dots, t + h$ ) (ver Figura 5.1). Para esto se analizan dos etapas de tiempo a la vez, donde la información en la etapa  $t$  se propaga a través de las etapas siguientes aplicando un proceso de inferencia bayesiana. La función de transición utilizada está definida por  $P(S_{t+1}|S_t, A_t, A_{t+1})$ . La selección de la mejor alternativa se basa en maximizar la función objetivo descrita por la expresión 5.1 en esta serie de etapas temporales. En los escenarios utilizados (ver Capítulo 5) la mejor alternativa consiste en:

- Mostrar la mejor vista en una aplicación de videoconferencias o,
- Mostrar el mensaje apropiado en una aplicación de apoyo a personas con problemas para realizar tareas.

La selección de la mejor acción debe enfrentar aspectos que caracterizan aplicaciones reales de toma de decisiones, tales como: (i) el manejo de la incertidumbre presente en el ambiente bajo observación y (ii) el efecto que tienen las acciones seleccionadas en los estados que representan a este ambiente. Los aspectos mencionados se deben manejar con eficacia para que un modelo sea útil en aplicaciones reales. Para esto, es necesario que el modelo sea confiable en seleccionar la acción óptima ante ligeras variaciones presentes en los objetivos del modelo y del usuario, asimismo, debe proporcionar resultados en un tiempo adecuado al escenario donde se aplica. El tiempo de respuesta,

depende en gran medida del mecanismo de inferencia utilizado. En este trabajo se aplica el algoritmo de Cooper [21] (ver Capítulo 3), con el fin de reducir la red de decisión manejada a una red bayesiana, posteriormente se utiliza el algoritmo de *Junction tree* [46], para realizar la inferencia en esta red. Este algoritmo es lo suficientemente rápido para ser aplicado en redes de tamaño moderado (unos cuantos cientos de nodos), tal como las redes que representan los escenarios utilizados en este trabajo. Sin embargo, cuando las redes son demasiado grandes (miles de nodos) y complejas es recomendable utilizar algoritmos de aproximación [40, 102].

En las redes de decisión dinámica (RDDs), el grado de aproximación a la solución de un problema POMDP depende del número de etapas temporales analizadas a futuro (grado de anticipación de la RDD). Aunque algunos investigadores [53] consideran un problema la determinación del número de etapas necesarias para seleccionar una acción, en este trabajo se resuelve esta situación estableciendo un compromiso entre la utilidad máxima esperada (UME) al analizar una secuencia de etapas temporales y el tiempo en el cual se obtiene dicho valor. Los criterios que se van a utilizar para evaluar el desempeño del modelo desarrollado se describen a continuación.

## 6.2. Criterios de evaluación

Para evaluar la eficiencia del modelo desarrollado en este trabajo se van a considerar los siguientes criterios:

1. **Tiempo de respuesta.** Las respuestas proporcionadas por el sistema deben ser generadas en un tiempo adecuado a la aplicación.
2. **Confiabilidad al seleccionar la mejor alternativa.** La selección de la mejor acción debe permanecer confiable aún ante ligeras variaciones en los valores de los parámetros del modelo, se determina con base en el comportamiento del usuario y los objetivos del modelo.

### 6.2.1. Tiempo de respuesta

Uno de los principales desafíos que enfrenta una red de decisión dinámica es la tratabilidad. En el peor caso, la inferencia en una red bayesiana es un problema *NP – duro*, tanto para algoritmos exactos [21], como para algoritmos aproximados [23], esto se observa en una amplia variedad de aplicaciones reales [11, 42, 79]. En ambientes reales, es importante que el modelo sea capaz de responder en un tiempo determinado con el fin de que sea de utilidad. Este tiempo normalmente es establecido por la aplicación, sin embargo, un criterio para determinarlo consiste en qué tanto se puede mantener el interés de un usuario en el sistema, ya sea observando información de una videoconferencia, o escuchando instrucciones para completar una tarea. De acuerdo a datos proporcionados por Fujitsu [111] en un trabajo realizado para evaluar algunas métricas que miden los niveles de servicios proporcionados por sistemas donde existe interacción con usuarios, sugiere un tiempo entre 1 y 2 segundos de tolerancia. Es decir, este intervalo indica el nivel de paciencia del usuario ante una respuesta del sistema. Por otro lado, Murray [80] en un trabajo relacionado con el diseño de sistemas tutores inteligentes, muestra que su sistema puede seleccionar acciones tutoriales en tiempos de respuestas satisfactorios los cuales ubica entre 7 y 8 segundos<sup>1</sup>. A su vez Conati [20] reporta tiempos de

---

<sup>1</sup>Estos fueron los tiempos menores que Murray reporta en su evaluación, sin embargo, tal evaluación fue realizada por estudiantes fuera de línea. Recientemente, realizó una comparación de su sistema, pero también fuera de línea [79].

respuesta superiores a 40 segundos, al evaluar un sistema tutor para el aprendizaje de física, por lo que maneja un tope de 40 segundos como el tiempo para que el sistema genere una respuesta (resuelva problemas de física). Por lo tanto, en este trabajo se considera satisfactorio el manejo de tiempos de respuesta en un rango entre 1 y 7 segundos.

El procedimiento para determinar el tiempo de respuesta proporcionado por el sistema al seleccionar la mejor acción es el siguiente:

1. El escenario de videoconferencia es representado por una RDD como la mostrada en la Figura B.1, esta red es analizada considerando un total de 7 etapas temporales en avance. Esta red se ejecutó durante 10 ocasiones consecutivas, y se anotó su tiempo de respuesta en cada caso. Los datos de esta red son: 21 nodos, 4 alternativas de acción (*Mostrar la pantalla, Mostrar el cuaderno, Mostrar el rostro, Mostrar el libro*), 56 estados y 212 parámetros.
2. El escenario de apoyo a discapacitados se representa por la RDD mostrada en la Figura B.4, esta red se analiza considerando 5 etapas temporales en avance. Al igual que la red anterior, se ejecuta un total de 10 ocasiones consecutivas y se anotan sus tiempos de respuesta. Los datos de esta red son: 14 nodos, 8 alternativas de acción (*Abre el grifo, Mójate la manos, Enjabónate las manos, Lávate las manos, Sécate las manos, Cierra el grifo, AcciónNula, Solicitar asistencia*), 65 estados y 6565 parámetros.
3. Los tiempos de respuestas obtenidos en las 10 lecturas de cada red, se promediaron para obtener el tiempo de respuesta promedio. Cabe mencionar, que no hubo variaciones significativas en los tiempos obtenidos en cada ejecución, por lo que podemos considerar que el tiempo promedio es el tiempo obtenido en cada ejecución de la red respectiva.
4. Se evaluaron 3 algoritmos de inferencia aplicados en redes bayesianas: (1) el algoritmo de agrupamiento (*clustering*) de Huang y Darwiche [47], el cual proporciona resultados exactos, (2) el algoritmo de muestreo estocástico (*probabilistic logic sampling*) de Henrion [40], el cual proporciona resultados aproximados, y (3) el algoritmo de muestreo estocástico (*likelihood sampling*) propuesto por Fung y Chang [33]. Los algoritmos de muestreo se probaron con 1000 muestras (el valor por omisión del SMILE) y con 10000 muestras.

Los resultados de esta prueba se muestran en la Tabla 6.1.

Los tiempos de respuesta proporcionados por el modelo que representa al escenario de videoconferencias (Escenario A en la Tabla) se encuentran dentro del rango sugerido como tiempo de respuesta satisfactorio. A su vez, el modelo que representa al escenario de apoyo a discapacitados (Escenario B en la Tabla), proporciona tiempos de respuesta mayores al sugerido, sin embargo, este tipo de aplicaciones puede tolerar tiempos de respuesta mayores [11]. Por lo tanto, se puede determinar que el modelo desarrollado proporciona respuestas en un tiempo adecuado para diferentes tipos de aplicaciones.

Tabla 6.1: Promedio de tiempos de respuesta proporcionados por el modelo en dos escenarios diferentes al seleccionar la acción óptima.

Algoritmo	Tiempo de respuesta (seg)	
	Escenario A	Escenario B
Exacto	5	32
Aproximado		
<i>Logic Sampling</i>		
1000 muestras	3	11
10000 muestras	3	12
<i>Likelihood Sampling</i>		
1000 muestras	3	12
10000 muestras	4	12

### 6.2.2. Confiabilidad al seleccionar la mejor alternativa

El modelo desarrollado selecciona la mejor acción en base a reconocer el comportamiento humano al interactuar con objetos de interés. El comportamiento del usuario al realizar una actividad varía en el tiempo, por lo tanto, afectar de forma positiva tal comportamiento de tal manera que le permita terminar su tarea es uno de los objetivos del sistema. El estado cambiante del usuario se representa a través de una red bayesiana dinámica (RBD, ver Capítulo 3) la cual consiste de varias etapas temporales, cada una representando el estado del usuario al estar realizando una actividad. Tales etapas pueden ser seleccionadas de tal forma que representen el modelo del usuario después de una acción, esto es más útil que emplear intervalos de tiempo fijos utilizados en algunos sistemas tutoriales [79, 100]. Los aspectos dinámicos del modelo se describen en detalle en los capítulos 4 y 5. Los aspectos relacionados con la actividad desarrollada en cada uno de los escenarios se define en base a conocimiento experto, esta información se determina por el *modelo del experto*.

**Modelo del Experto.** El modelo que representa el conocimiento experto define el espacio de representación del problema, incluyendo conceptos relacionados al dominio. Por ejemplo, en el escenario de apoyo a discapacitados el experto debe indicar la secuencia de pasos correcta para completar una tarea, decidir que hacer en caso de no cumplirse estos pasos, y mantener la independencia del usuario (uno de los objetivos). Este modelo se encarga de lo siguiente:

- Define el conjunto de acciones disponibles al sistema.
- Define la forma de seleccionar tales acciones en base al comportamiento del usuario.
- Define el esquema para seleccionar las acciones.
- Proporciona apoyo al usuario en un tiempo adecuado.

A partir de la información del conocimiento experto, el modelo intenta emular el comportamiento exhibido por humanos en cada situación, por ejemplo en el escenario de apoyo a personas con alguna discapacidad:

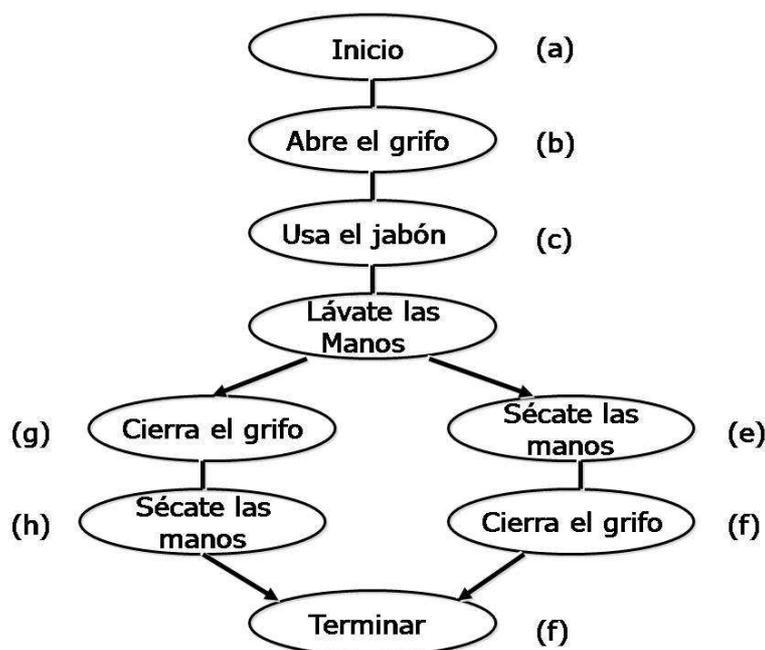


Figura 6.1: Secuencia de pasos definido por el experto para realizar la actividad: *asearse las manos*. La secuencia de pasos  $a - d$  debe ser realizada en ese orden, posteriormente el usuario puede elegir una de dos opciones ( $g - h$ ,  $e - f$ ) para continuar con los pasos y llegar a terminar la tarea.

- El modelo no proporciona ayuda cuando cree que la persona no la necesita. Permitiendo en este caso apoyar la independencia de la persona al realizar su trabajo sin interferir. Un asistente humano permite a las personas realizar su tarea cuando son capaces de realizarla por sí solas de manera exitosa.
- Cuando el modelo considera que la persona necesita ayuda, se la proporciona con el fin de que pueda completar su tarea. Los asistentes humanos proveen la ayuda necesaria a las personas cuando saben que es necesario para que realicen su tarea, antes que puedan cometer un error.
- El modelo evita acciones incoherentes, por ejemplo instruir a la persona para que se seque las manos cuando debe lavarse primero. Los asistentes humanos toman este tipo de acciones para corregir a la persona cuando está realizando pasos para completar una tarea.
- El modelo se basa en preferencias para decidir entre varios tipos de acciones de acuerdo a una estructura de preferencias (modelo de utilidad). Los asistentes humanos exhiben diferencias en sus preferencias para tomar acciones. Por ejemplo, alguien puede preferir indicarle a una persona lo que debe hacer desde un principio, mientras otra prefiera que la persona tome la iniciativa.

Para la realización de los primeros 3 puntos, el sistema se apoya en un grafo (ver Figura 6.1) que indica la secuencia de pasos que debe realizar el usuario para completar la tarea: *Asearse las manos*. Una estructura similar ya ha sido utilizada en trabajos previos [11, 42, 79], por el momento el grafo opera en base a reglas, será un trabajo posterior buscar la manera de integrarlo al modelo. Los puntos anteriores son la base para definir la estructura del modelo de utilidades en este escenario (ver Apéndice B).

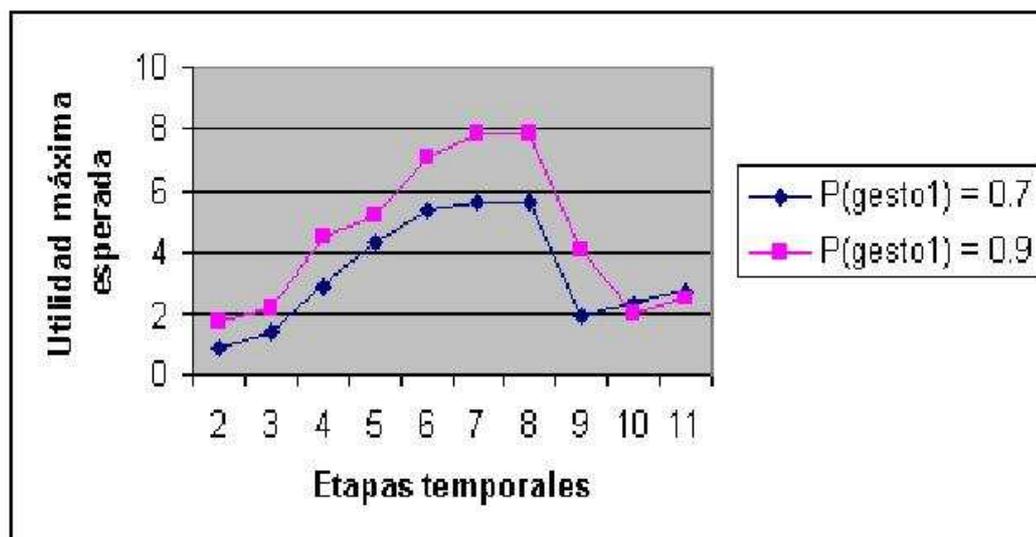


Figura 6.2: Imagen que ilustra la gráfica obtenida en el modelo de RDD utilizada en el escenario de videoconferencia, al variar las creencias del modelo. El gesto al cual se le varía la probabilidad es: *Hojeando el libro*.

El procedimiento para evaluar la confiabilidad del modelo para seleccionar la mejor alternativa es el siguiente:

1. Variación de las creencias del sistema. Se varían las creencias (*probabilidades a priori y condicionales*) del sistema con respecto al comportamiento del usuario. Para este análisis se realizó la variación de las probabilidades *a priori* del modelo en cada uno de los escenarios. Se utilizaron dos valores de probabilidad (0,7 y 0,9) para cada uno de los gestos. Posteriormente aplicando librerías de SMILE<sup>2</sup>, se calcula la máxima utilidad esperada, a partir de la cual se selecciona la acción óptima. La acción óptima se anotó en cada uno de los casos al variar el número de etapas temporales. La Figura 6.2, muestra el comportamiento de la red que representa al escenario de videoconferencias al variar las creencias en el modelo. Se observa en la gráfica que la máxima utilidad esperada se incrementa gradualmente hasta obtener un valor máximo en las etapas temporales 7 y 8, posteriormente se muestra un decremento y nuevamente se observa un incremento en la etapa temporal 11. En cada una de las etapas temporales se obtuvo la decisión correcta indicada por la máxima utilidad esperada. En la gráfica se observa que el comportamiento de la red no cambia al variar la probabilidad *a priori* de los gestos reconocidos. Es decir, el valor de la máxima utilidad esperada varía al variar la probabilidad *a priori*, sin embargo el comportamiento observado es el mismo, esto puede apreciarse en la forma de la gráfica.

Este mismo efecto se muestra en la red que representa al escenario de apoyo a discapacitados (ver Figura 6.3). En este caso, el gesto mostrado en la gráfica es: *Abriendo el grifo*, y mediante la Ec. 5.1 (es la que utiliza la librería SMILE), se obtuvo la máxima utilidad esperada para la acción: *Mojarse las manos*. Esta será la acción que definirá el mensaje audible emitido por el sistema si resulta necesario apoyar al usuario. el comportamiento de la RDD indica un incremento gradual en el valor de la máxima utilidad esperada en las etapas temporales analizadas<sup>3</sup>.

<sup>2</sup>Structural Modeling, Inference, and Learning Engine), librería de clases en C++ desarrollada en el Laboratorio de Sistemas de Decisión de la Universidad de Pittsburg

<sup>3</sup>Las etapas temporales analizadas para cada escenario fueron limitadas por el software utilizado (GeNIE y SMILE),

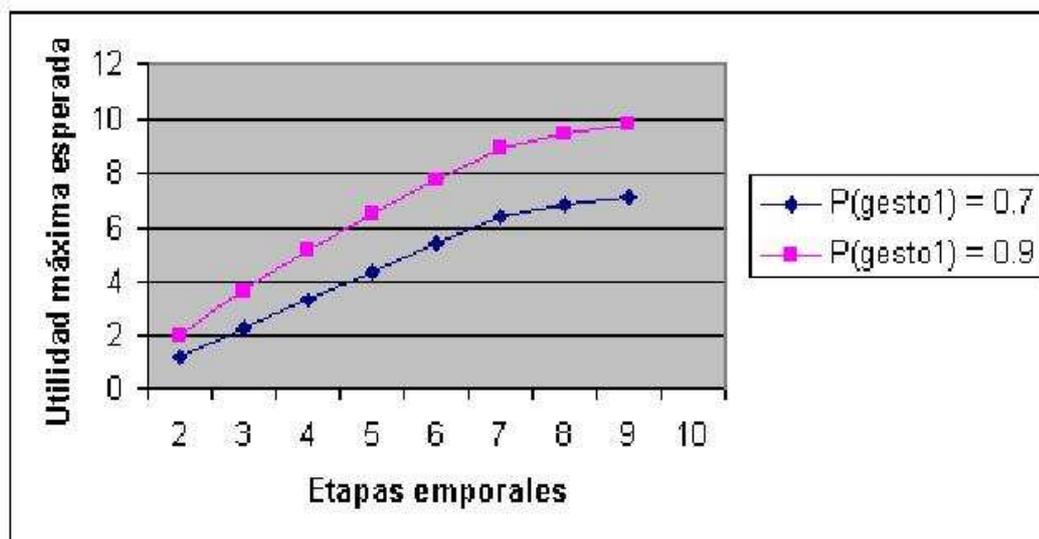


Figura 6.3: Imagen que muestra el comportamiento del modelo que representa al escenario de apoyo a discapacitados, cuando se varían las creencias. En este caso, el gesto que se varía es: *abriendo el grifo*, con valores de probabilidad de 0,7 y 0,9.

La acción seleccionada en cada una de las etapas temporales es la esperada y definida en base a preferencias determinadas por conocimiento experto (utilizando referencias de trabajos similares [11, 41]). Aunque se observa una variación en los valores de máxima utilidad esperada al variar la probabilidad *a priori* del gesto mostrado, el comportamiento no varía, y la acción seleccionada es la misma en cada caso.

2. Variación de los objetivos del modelo. Para este análisis, se varían los objetivos del modelo (representados por los valores de utilidad), y se observa la acción óptima seleccionada al variar las etapas temporales. En la Figura 6.4 se muestra el comportamiento de la utilidad máxima esperada al variar la utilidad o preferencias del sistema en la red que representa el escenario de videoconferencias. Los valores de utilidad aplicados en este modelo son los siguientes: [-3, +3], [-1, +1] y [0, +1], los valores negativos [-3, -1] y 0 indican penalizaciones, mientras que los valores positivos [+1, +3] indican recompensas o preferencias hacia los resultados esperados. Para cada uno de los escenarios, se mantuvo constante la probabilidad *a priori* en cada uno de los gestos. La Figura 6.4, muestra el comportamiento del modelo indicado por el valor de la utilidad máxima esperada al variar la utilidad y el número de etapas temporales. Aunque el comportamiento muestra variaciones en el valor de la utilidad máxima, en relación al uso de valores positivos y negativos, la acción seleccionada por el modelo es la correcta. En la gráfica mostrada, al gesto: *Usar el mouse*, se le asignó una probabilidad *a priori* de 0,9, la acción seleccionada al emplear diferentes etapas temporales (2 – 11) fue la correcta (*Mostrar la pantalla*).

El comportamiento de La RDD que representa el escenario de apoyo a discapacitados, se muestra en la Figura 6.5. En esta red se utilizaron los siguientes valores para la matriz de utilidades: [-6, -3, +3], [-6, -1, +1], [-6, 0, +1]. El valor de -6, en este caso indica una alta penalización, con el fin de evitar la selección de alguna alternativa. En este caso, este valor se asigna a la acción

sin embargo, en este trabajo se considera que no es relevante continuar el análisis para un mayor número de etapas, ya que en el escenario de videoconferencias ejecutar la red con 11 etapas temporales consume un tiempo de 540 segundos. Mientras que en la RDD del escenario de apoyo a discapacitados obtener la acción óptima con 9 etapas analizadas se obtiene en 187 minutos.

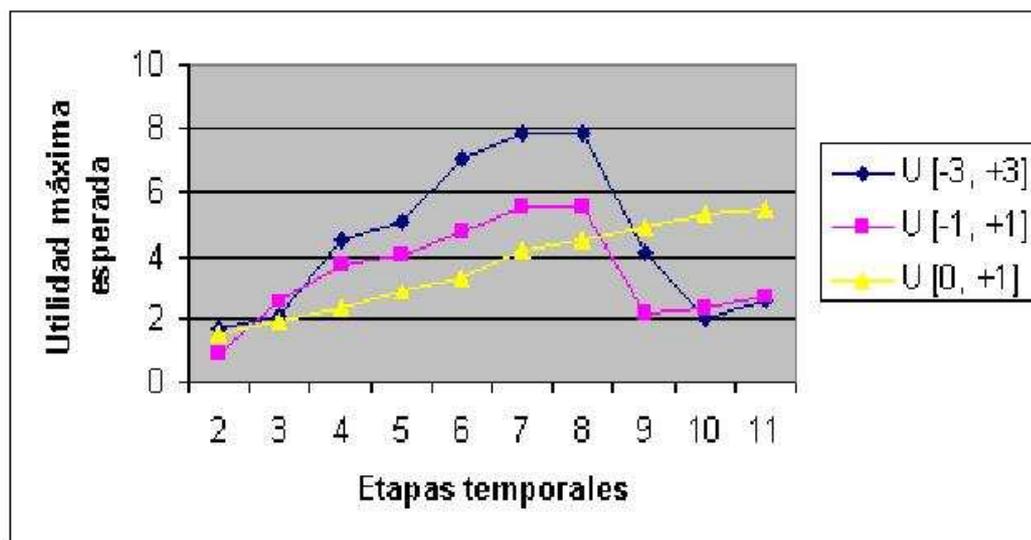


Figura 6.4: Imagen que ilustra el comportamiento del modelo al variar los valores de utilidad. Se observa que el valor de la utilidad máxima esperada se incrementa gradualmente, alcanza un valor máximo y empieza a decrementar cuando se manejan utilidades negativas y positivas. Mientras que se observa un incremento constante, el cual es cada vez menor en las etapas finales de análisis al no usar valores negativos. Sin embargo, la acción seleccionada en cada caso se mantiene constante.

de *Solicitar asistencia* la cual debe dejarse como la opción final para un sistema que apoya a personas discapacitadas. El comportamiento del modelo al variar las utilidades es similar para los tres casos analizados, mostrando diferencias en los valores obtenidos para la máxima utilidad esperada lo cual es obvio considerando los valores manejados para las utilidades. En la imagen se muestra la acción seleccionada por el modelo al asignar una probabilidad *a priori* de 0,9 al gesto de *Abriendo el grifo*.

Del análisis anterior se puede concluir que el modelo desarrollado es estable ante ligeras variaciones en los objetivos, es decir, selecciona la acción óptima apropiada ante variaciones de las creencias y objetivos del modelo analizados en avance a través de una secuencia de etapas temporales. Asimismo, se determina que es eficaz en su desempeño ya que toma decisiones (selecciona respuestas) en un tiempo adecuado a los escenarios utilizados. Desde luego, este modelo aún es susceptible de ser mejorado en algunos aspectos con el fin de ser aplicado a escenarios *más realistas* (por ejemplo en videoconferencias: reconocer un mayor número de gestos, varios objetos del mismo tipo, uso de ambas manos por parte del expositor).

### 6.2.3. Selección de la RDD utilizada

A partir de las pruebas realizadas se determina que el modelo desarrollado responde de manera adecuada ante el comportamiento humano observado en distintos escenarios. Sin embargo, debemos considerar un tiempo de respuesta apropiado para cada escenario mucho menor al determinado por Conati y otros [20], por ejemplo, en el escenario de videoconferencias es conveniente manejar un tiempo menor a 2 segundos [111], mientras que en el escenario de apoyo a discapacitados se puede tolerar un tiempo mayor [11]. La Figura 6.6 muestra el valor alcanzado por la utilidad máxima espera-

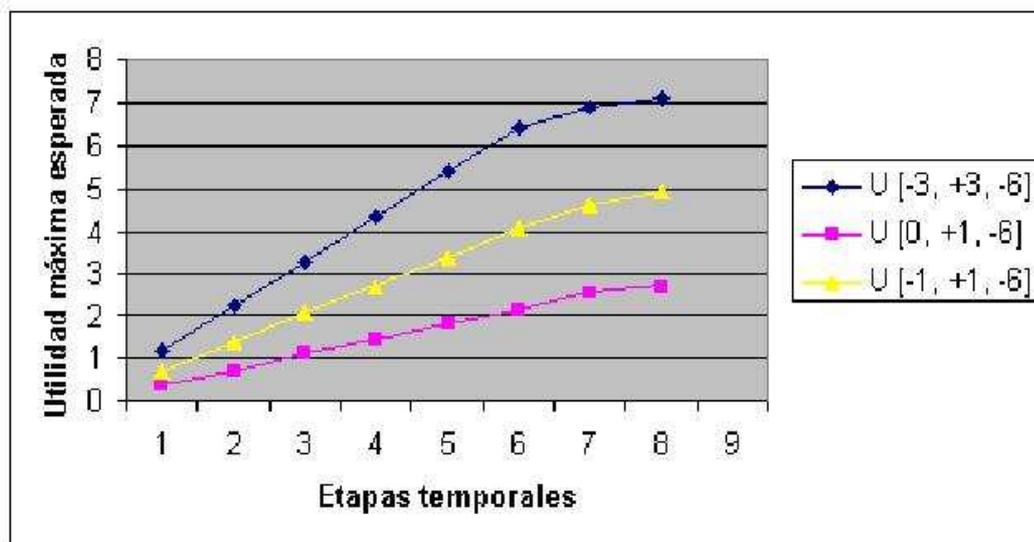


Figura 6.5: Imagen que ilustra el comportamiento del modelo al variar los objetivos del mismo (valor de las utilidades), manteniendo constante el valor de las creencias (probabilidad *a priori* asignada a un gesto) y considerando el análisis en varias etapas temporales en avance.

da al incrementarse el número de etapas temporales analizadas en el escenario de videoconferencias, así como el tiempo en el que se obtiene dicho valor. Se observa en la Figura 6.6 que el valor máximo para la utilidad esperada se obtiene al analizar 8 etapas temporales en un tiempo de 34 segundos. Para que una RDD sea de utilidad en ambientes reales, es necesario que el tiempo de respuesta sea apropiado a la aplicación. Por lo tanto, se debe generar un compromiso entre el valor máximo de la utilidad esperada y el tiempo en el que se obtiene. Se determina del análisis mostrado en la sección anterior, que la selección de la mejor acción no cambia al variar de 8 a 5 el número de etapas temporales analizadas. Por lo tanto, se determinó en este trabajo utilizar una RDD de 5 etapas temporales para aplicarse en el escenario de videoconferencias, esta red genera respuestas en un tiempo menor a 2 segundos. Asimismo, se determinó utilizar una RDD con 4 etapas temporales para aplicarse en el escenario de apoyo a discapacitados, esta red proporciona la respuesta en un tiempo menor a 3 segundos.

### Efecto del factor de descuento en las etapas temporales analizadas

El factor de descuento  $\gamma$ , que aparece en la expresión 5.1 se emplea en problemas POMDP con horizonte infinito con fin de acelerar la convergencia del modelo a un valor de terminación. Se va a analizar el efecto que tiene este factor en redes de decisión dinámicas que modelan problemas POMDP con horizonte finito. Al analizar la utilidad obtenida por la RDD que representa el escenario de videoconferencias durante varias etapas temporales, observamos algo interesante. La utilidad se incrementa gradualmente conforme se incrementa el número de etapas. Sin embargo, al observar el valor de utilidad en cada nodo de valor de las etapas individuales, el valor se incrementa en las primeras etapas y posteriormente disminuye hasta estabilizar su valor (ver Figura ??). Por lo tanto, bajo esta observación es posible considerar un esquema para determinar el número de etapas temporales  $h$ , necesarias para obtener la utilidad máxima esperada. Esta consideración puede ser en el punto donde los valores de utilidad en dos nodos de valor consecutivos sean muy similares (difieran en 0.001, por ejemplo, este dato se obtuvo de forma experimental). En el escenario de videoconferencias, este valor se obtiene entre las etapas 7 y 8. Al considerar la selección del número de etapas temporales aplicando

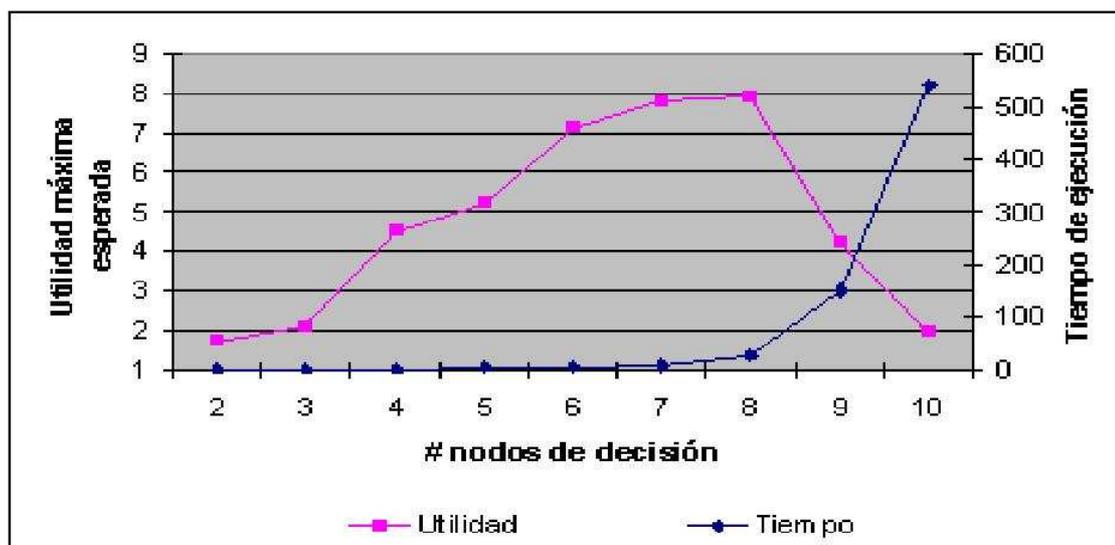


Figura 6.6: Tiempo en que se obtiene la máxima utilidad esperada en el escenario de videoconferencias al variar el número de etapas temporales analizadas. Los datos mostrados corresponden a la modelación del gesto: *hojeando el libro*, con una probabilidad *a priori* de 0.9, y valores de utilidades de +1 y -1. La obtención de la utilidad máxima esperada ocurre en la etapa temporal 8.

un factor de descuento  $\gamma$ . Se observa (ver Figura ??), que las utilidades obtenidas considerando diferentes valores de descuento disminuyen y, aunque el factor de descuento lleva al sistema a una rápida convergencia, el número de etapas donde se obtiene un valor estable no varía. Por lo tanto, concluimos que no es necesario considerar el factor de descuento para determinar el número de etapas donde se debe seleccionar la acción óptima. La RDD que utilizada en el escenario de apoyo a discapacitados muestra un comportamiento similar.

El número de etapas a considerar, lo determina la etapa donde se obtiene el primer valor pico de la utilidad máxima esperada. Los resultados mostrados en este escenario, manejando esta suposición muestran resultados satisfactorios en el rendimiento del sistema. Este análisis puede considerarse apropiado en aplicaciones con características similares a la mencionada.

#### 6.2.4. Comparación del modelo contra un operador humano

Además de las pruebas realizadas al modelo para verificar su eficacia y confiabilidad, se realiza una prueba adicional para estimar su desempeño por parte de usuarios. En esta prueba, se compara la confiabilidad del modelo para seleccionar acciones óptimas, contra la selección de acciones óptimas realizadas por un operador humano. La información analizada son respuestas obtenidas a través de una encuesta aplicada a *usuarios* finales (audiencia que observa una videoconferencia, personas que simulan tener problemas de memoria). El instrumento de evaluación que vamos a utilizar es el indicador de Likert<sup>4</sup> [109]. La escala que se va a manejar es de 1 a 5, donde:

<sup>4</sup>El indicador de Likert es una escala aditiva. Las escalas aditivas están constituidas por una serie de ítems ante los cuales se solicita la reacción del sujeto. El interrogado señala su grado de acuerdo o desacuerdo con cada ítem (muy de acuerdo, de acuerdo, indeciso en desacuerdo, muy en desacuerdo). A cada respuesta se le da una puntuación favorable o desfavorable. La suma algebraica de las puntuaciones de las respuestas del individuo a todos los ítems da su puntuación total que se entiende como representativa de su posición favorable-desfavorable con respecto al fenómeno que se mide.

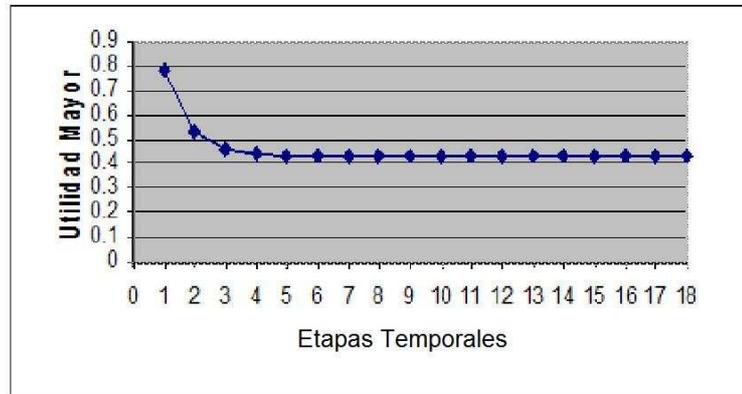
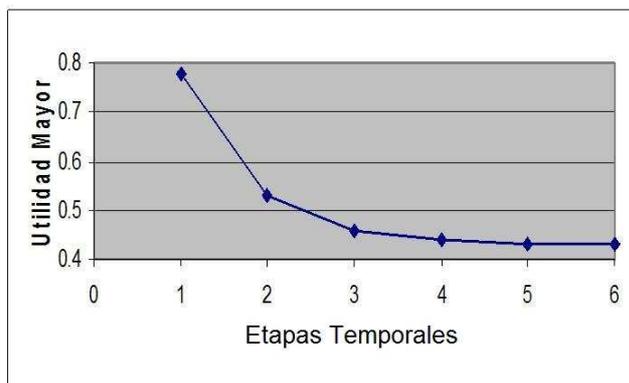
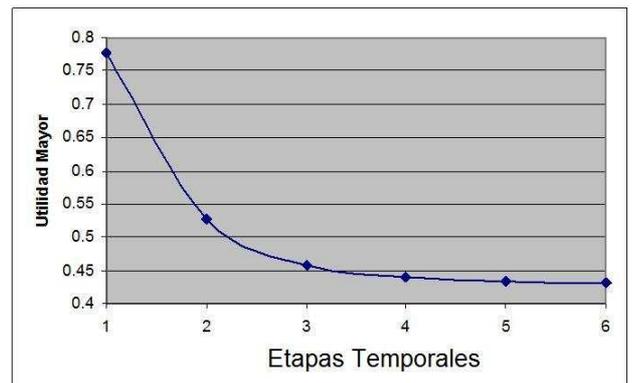


Figura 6.7: Gráfica que ilustra la manera en que cada nodo de valor disminuye gradualmente su valor hasta llegar a un valor estable con un factor de descuento  $\gamma=1$ .



(a)



(b)

Figura 6.8: Las imágenes ilustran dos gráficas mostrando el efecto del factor de descuento  $\gamma$  en el valor de la utilidad en cada etapa temporal. La gráfica (a) se muestra el efecto en el valor de utilidad al aplicar un  $\gamma$  de 0,9. En la gráfica (b) se aplica un factor de descuento  $\gamma$  de 0,7.

1. = muy en desacuerdo.
2. = en desacuerdo.
3. = indeciso.
4. = de acuerdo.
5. = muy de acuerdo.

En el escenario de videoconferencia nos interesa evaluar los siguientes criterios:

- **Congruencia.** Indica la consistencia entre la información observada por la audiencia y lo que está realizando el conferencista.
- **Sensibilidad.** Indica la respuesta del sistema ante los cambios en los gestos del expositor.
- **Estabilidad.** Indica la intermitencia de las imágenes observadas por la audiencia al pasar el expositor de un gesto a otro y consecuentemente al cambiar el sistema de una acción a otra.

Por lo tanto, las preguntas realizadas a los participantes a través de un cuestionario, están dirigidas a obtener información de los criterios anteriores, y son las siguientes:

1. Lo que se muestra en la pantalla corresponde a lo que explica el expositor.
2. Las imágenes permanecen el tiempo suficiente en la pantalla para permitir apreciar la exposición
3. El cambio entre las imágenes no afecta la exposición.

A la vez en el escenario de apoyo a discapacitados nos interesa conocer la eficiencia del sistema para guiar a una persona a terminar una tarea. Por lo tanto, la evaluación se basa en los siguientes criterios:

- **Grado de especificación de los mensajes.** Indica el grado de detalle de las instrucciones audibles [11], en este trabajo aplicamos una especificación general (no se menciona el nombre del usuario, ni se describen en detalle los objetos: color y localización) para cada uno de los mensajes.
- **Oportuno.** Indica si el mensaje se proporciona en el momento oportuno. La instrucción: *Enjabónate las manos* debe seleccionarse cuando el modelo determina que el usuario ya tiene las *manos mojadas* y está realizando una actividad diferente a: *Enjabonándose las manos*.
- **Efectivo.** Indica si el mensaje seleccionado guía de manera efectiva a una persona, es decir, si la hace pasar de un paso a otro de la tarea en el orden indicado en el grafo de tareas (ver Figura 6.1).

Las preguntas manejadas en este escenario son las siguientes:

1. ¿Las instrucciones escuchadas son comprensibles?.
2. ¿Las instrucciones se proporcionaron en el momento oportuno?.
3. ¿Los mensajes escuchados ayudan a terminar una tarea?.

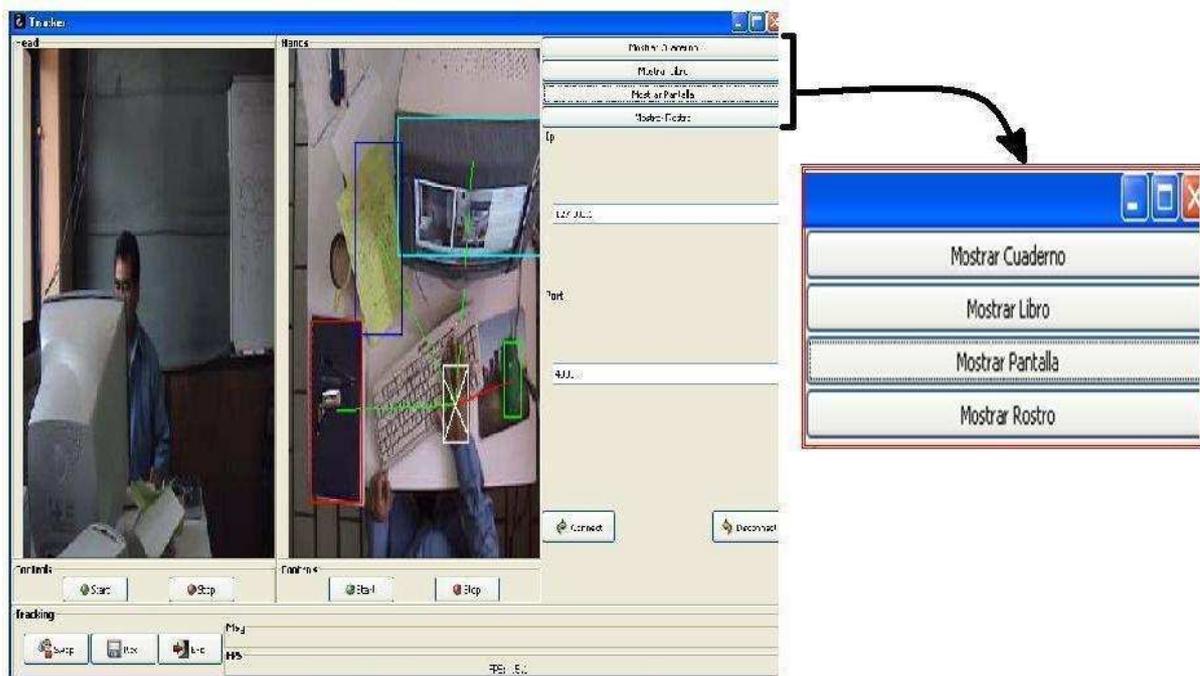


Figura 6.9: Imagen que ilustra la interfaz que aparece en la pantalla del operador humano encargado de seleccionar la información enviada a los alumnos. En la esquina superior derecha de la imagen aparecen las acciones que puede seleccionar (mostradas en detalle en el recuadro).

### Procedimiento de evaluación

**Evaluación del modelo aplicado en el escenario de videoconferencia.** Para evaluar el modelo que toma decisiones en el escenario de videoconferencia, se seleccionó una muestra de 20 estudiantes de nivel licenciatura<sup>5</sup>, los cuales fueron divididos en 2 grupos de 10. Estos grupos evaluaron la exposición a través de la encuesta correspondiente al escenario en cuestión. Uno de los grupos evaluó la toma de decisiones realizada por el modelo desarrollado, mientras el otro evaluó la toma de decisiones realizada por el operador humano. El espacio donde se encontraba el expositor y el operador humano se encuentra separado del espacio donde se encontraban los grupos de alumnos. Por lo tanto, los participantes en ningún momento tuvieron conocimiento de quién seleccionaba la información que observaban en la pantalla. El expositor realizó una corta exposición (5 minutos) donde utilizó material didáctico (hoja de papel, libro, computadora) para apoyarse. La misma exposición la repitió en dos ocasiones, en la primera, las acciones fueron seleccionadas por un operador humano (ver Figura 6.9), mientras que en la segunda las acciones fueron seleccionadas de manera automática por el modelo. Los resultados de la encuesta realizada se muestran en las Tablas 6.2 y 6.3.

En la Tabla 6.4 se muestra una comparación de los resultados obtenidos en la encuesta aplicada al grupo de estudiantes seleccionados (en la Figura 6.10 se ilustra esta comparación). Los datos obtenidos, ofrecen un indicador del rendimiento del modelo computacional desarrollado con base en datos estadísticos (la media y la desviación estándar) de los datos para cada aspecto de interés al aplicar el

<sup>5</sup>Aunque pudiera parecer que la muestra utilizada no es representativa por ser un grupo reducido de personas y con características similares, para la finalidad de la evaluación se considera una muestra representativa de los usuarios del sistema diseñado, ya que se puede obtener información que indiquen una tendencia general.

Tabla 6.2: Puntaje obtenido al evaluar la toma de decisiones realizada por un operador humano en un escenario de videoconferencia. La evaluación fue realizada por un grupo de 10 participantes. El puntaje mínimo es 1 y el máximo 5 al aplicar la escala de Likert. Se muestra información estadística (media aritmética y desviación estándar muestral) para cada uno de los aspectos que interesa conocer.

Ítems	Participantes										$\Sigma$	prom.	S
	1	2	3	4	5	6	7	8	9	10			
(1)	4	4	5	5	4	4	5	4	4	4	43	4.3	0.48
(2)	4	4	4	4	4	5	5	4	4	4	42	4.3	0.48
(3)	4	4	4	4	4	4	5	4	4	5	42	4.2	0.42

Tabla 6.3: Puntaje obtenido al evaluar la toma de decisiones realizada por el modelo desarrollado en este trabajo en un escenario de videoconferencia. La evaluación fue realizada por un grupo de 10 participantes, diferente a los que evaluaron la toma de decisiones realizada por un humano. El puntaje mínimo es 1 y el máximo 5.

Ítems	Participantes										$\Sigma$	prom.	S
	1	2	3	4	5	6	7	8	9	10			
(1)	4	2	3	4	4	4	5	4	4	4	38	3.8	0.78
(2)	4	2	2	4	4	4	5	4	4	4	37	3.7	0.94
(3)	4	4	2	4	4	4	5	4	4	4	39	3.9	0.73

indicador de Likert<sup>6</sup>. A pesar de que los resultados muestran una tendencia favorable en el desempeño del operador humano comparado con el modelo desarrollado, la diferencia no es considerable (ver tabla 6.4. Considerando los datos obtenidos, la media teórica se calcula de la siguiente manera:

$$\frac{10 \times 1 + 10 \times 5}{2} = 30 \quad (6.1)$$

Mientras que la media obtenida por el modelo tiene un valor de 38. Por lo tanto, de acuerdo con esta técnica, la tendencia de la muestra poblacional hacia la métrica que se está evaluando: el rendimiento del modelo para tomar decisiones, resulta favorable.

Asimismo, la información proporcionada por la desviación estándar<sup>7</sup> muestral (**S**), indica que no existe una dispersión significativa ( $< 1,0$ ) en la tendencia de los participantes hacia las acciones tomadas por el modelo.

Por lo tanto, y con base en la información anterior, se puede considerar que la toma de decisiones realizada por el modelo en el escenario de videoconferencia es satisfactoria.

Tabla 6.4: Concentrado de los resultados obtenidos al evaluar la toma de decisiones realizada por el modelo contra la realizada por un operador humano aplicando el indicador de Likert [109].

Aspecto evaluado	Selección de vistas realizada automáticamente	Selección de vistas realizada por un humano	Diferencia relativa (%)
Congruencia	3.8	4.3	12
Sensibilidad	3.7	4.3	14
Estabilidad	4.1	4.2	3
Promedio	3.86	4.25	10

**Evaluación del modelo aplicado en el escenario de apoyo a discapacitados.** Para evaluar el modelo que toma decisiones en el escenario de apoyo a discapacitados, se seleccionó una muestra poblacional

<sup>6</sup>A pesar de la ausencia de teoría justificativa para la *escalabilidad*, en la práctica, las puntuaciones del cuestionario Likert proporcionan con frecuencia un indicador confiables de la característica que se mide.

<sup>7</sup>La desviación estándar es un parámetro que ofrece información relacionada con la dispersión de los datos. Si se obtiene, a partir de una muestra poblacional, una desviación estándar con valor menor a 1, se puede deducir que la variación en este valor no será significativo al aumentar el tamaño de la muestra. Esto es útil, cuando resulta costoso realizar pruebas experimentales utilizando espacios muestrales grandes, como es el caso que se presenta en este trabajo, así como en otros similares [11, 80].

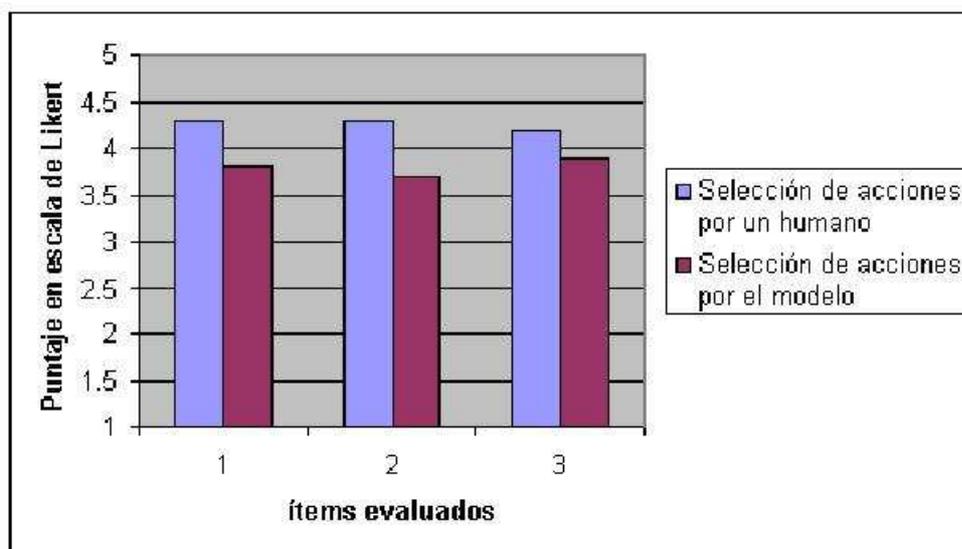


Figura 6.10: Concentrado de los resultados obtenidos al evaluar la toma de decisiones realizada por el modelo contra la realizada por un operador humano en un ambiente de videoconferencia, aplicando el indicador de Likert [109]. Los ítems evaluados corresponden a: (1) Congruencia, (2) sensibilidad, (3) Estabilidad.

formada por 10 personas adultas y al igual que el escenario anterior, fueron divididas en dos grupos de 5 participantes cada uno. El primer grupo, evaluó la toma de decisiones realizada por el modelo computacional desarrollado, mientras el segundo grupo, evaluó la toma de decisiones realizada por un asistente humano. Se les solicitó a los participantes que simularan tener problemas de memoria y de concentración para realizar y completar una tarea. Cabe mencionar que ninguno de los participantes tiene experiencia alguna con este tipo de problemas, esto lejos de ser un inconveniente se considera que es una ventaja, ya que pueden reaccionar de una forma más natural a las instrucciones verbales.

Los resultados obtenidos al evaluar los tres aspectos de interés en este escenario se muestran en las Tablas 6.5 y 6.6.

La Tabla 6.7 muestra los resultados comparativos de la evaluación proporcionada por un grupo de participantes para medir el desempeño del modelo y un asistente humano, en un escenario simulado de apoyo a discapacitados (la Figura 6.11 ilustra la comparación). Lo que se mide es el desempeño del modelo basado en tres criterios con el fin de seleccionar la instrucción verbal adecuada para guiar a una persona (que simula problemas de memoria y/o concentración) a completar una tarea. Los resultados mostrados de forma gráfica en la Figura 6.11, muestran una tendencia favorable hacia el asistente humano. Sin embargo, al igual que el escenario anterior, la diferencia en los valores de esta tendencia no es muy significativa, y en cierta forma los datos obtenidos también son favorables al modelo desarrollado. Esta asunción, se puede basar en el siguiente análisis: (i) la media de las preferencias obtenida por el modelo en cada uno de los criterios evaluados se ubica por encima de la media teórica, la cual tiene un valor de:

$$\frac{5 \times 1 + 5 \times 5}{2} = 15 \quad (6.2)$$

Tabla 6.5: Puntaje obtenido al evaluar la toma de decisiones realizada por un asistente humano. La evaluación fue realizada por un grupo de 5 participantes. El puntaje mínimo es 1 y el máximo 5.

Ítems	Participantes					$\Sigma$	prom.	S
	1	2	3	4	5			
(1)	4	5	5	4	4	22	4.4	0.54
(2)	5	5	5	4	4	23	4.6	0.54
(3)	4	5	4	4	4	21	4.2	0.44

Tabla 6.6: Puntaje obtenido al evaluar la toma de decisiones realizada por el modelo, operando en un escenario simulado de apoyo a discapacitados. La evaluación fue realizada por un grupo de 5 participantes. El puntaje mínimo es 1 y el máximo 5.

Ítems	Participantes					$\Sigma$	prom.	S
	1	2	3	4	5			
(1)	4	4	3	4	4	19	3.8	0.44
(2)	4	4	3	4	4	19	3.8	0.44
(3)	4	4	4	3	4	18	3.6	0.54

Mientras que la media del modelo equivale a:

$$\frac{19 + 19 + 18}{3} = 18,66 \quad (6.3)$$

Por lo tanto, y de acuerdo con la escala de Likert, se deduce que la tendencia de la muestra poblacional hacia la métrica que se está evaluando (el rendimiento del modelo para tomar decisiones) resulta favorable.

(ii) Además, y al igual que en el escenario anterior, el valor calculado para la desviación estándar muestral ( $S$ ) es pequeño ( $< 1,0$ ), esto indica que no existe una dispersión significativa en la tendencia de los participantes hacia las acciones tomadas por el modelo.

Por lo tanto, y con base en la información en el análisis anterior, se puede considerar que la toma de decisiones realizada por el modelo en el escenario de apoyo a discapacitados resulta satisfactoria.

Tabla 6.7: Concentrado de los resultados obtenidos al evaluar la toma de decisiones realizada por el modelo contra la realizada por un asistente humano en un escenario simulado de apoyo a discapacitados, la evaluación se realiza utilizando el indicador de Likert [109].

Aspecto evaluado	Instrucciones seleccionadas por el modelo	Instrucciones seleccionadas por un humano	Diferencia relativa (%)
Especificación	3.8	4.6	18
Oportuno	3.8	4.6	18
Efectivo	3.6	4.4	19
Promedio	3.66	4.53	18.3

Los resultados obtenidos, para evaluar el rendimiento del modelo computacional desarrollado en este trabajo, a partir de una muestra poblacional y aplicando la escala de Likert se pueden considerar satisfactorios. Existen trabajos similares [11, 80] al presentado en esta tesis, donde resulta costoso disponer de muestras poblacionales representativas, y por lo tanto, se confía en los resultados proporcionados por datos estadísticos muestrales como la media y la desviación estándar. Considerando que una desviación estándar con un valor pequeño ( $< 1$ ) obtenido de una muestra poblacional, varía muy poco al aumentar el tamaño de la muestra, se puede llegar a resultados concluyentes.

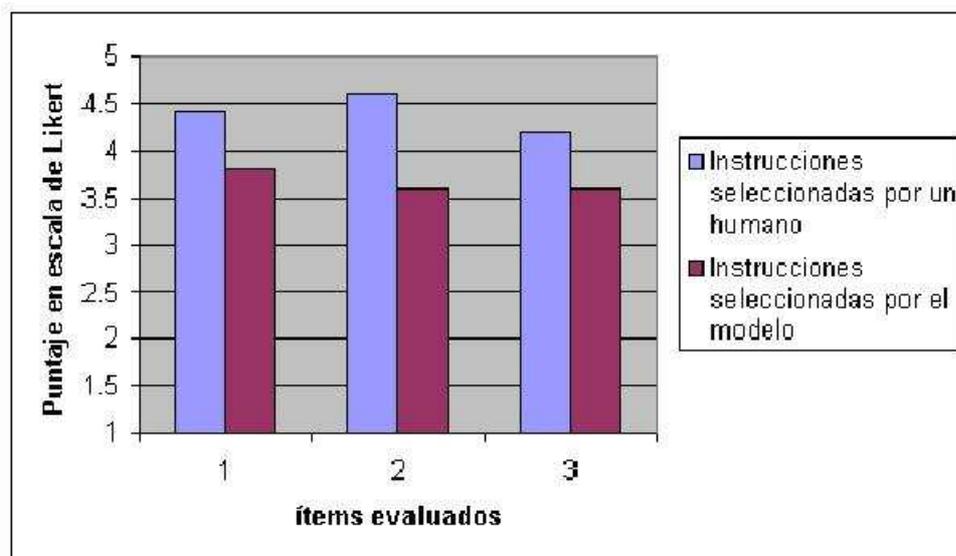


Figura 6.11: Ilustración de la comparación entre la toma de decisiones realizada por un humano y la realizada por el modelo desarrollado, en un escenario simulado de apoyo a discapacitados. Los datos mostrados por la escala de Likert indican una tendencia favorable hacia el asistente humano. Los ítems evaluados corresponden a: (1) Grado de especificación, (2) Oportuno y, (3) Efectividad.

### 6.3. implementación

Estas pruebas fueron realizadas utilizando una computadora Pentium 4, 3.1 GHz, 1 GB de RAM y plataforma Windows XP. La inferencia en las redes de decisión fue realizada utilizando la librería SMILE (Structural Modeling, Inference, and Learning Engine) versión 7.1 (2005-12-07) desarrollada en el Laboratorio de Sistemas de Decisión de la Universidad de Pittsburg<sup>8</sup>, la cual es una librería de clases desarrollada en C++ para el razonamiento en modelos gráficos probabilistas. El algoritmo de inferencia utilizado para evaluar la red de decisión dinámica es el de Cooper [21], el cual reduce los nodos de decisión y de utilidad a nodos aleatorios. Posteriormente se realiza la proyección probabilística utilizando un algoritmo exacto propuesto por Huang y Darwiche [47], el cual proporciona resultados exactos y permite el análisis de un mayor número de etapas temporales. El tiempo de respuesta se midió como el tiempo tomado para actualizar la red de decisión al seleccionar la acción óptima. El tiempo reportado es el tiempo promedio en segundos obtenido en 10 ejecuciones consecutivas del modelo. Se consideraron redes de decisión con distintos nodos de decisión (3-10).

### 6.4. Resumen de capítulo

Las pruebas realizadas para evaluar la utilidad del modelo en distintos escenarios muestran en general un resultado satisfactorio. Los escenarios utilizados son: (i) videoconferencias, en el cual el modelo debe seleccionar la mejor vista de una exposición para mostrarla a la audiencia y (ii) apoyo a discapacitados, donde el sistema debe guiar en un ambiente simulado a una persona con problemas de memoria a completar una tarea. La evaluación se dividió en dos etapas, en la primera se midió la eficiencia del modelo bajo dos criterios: **tiempo de respuesta** y **Confiabilidad del modelo para**

<sup>8</sup><http://www.pit.edu/>

**seleccionar la mejor acción**, en la segunda etapa se midió el rendimiento del modelo en los escenarios mencionados a partir de una encuesta realizada a dos grupos de participantes. En el primer enfoque, se verificó la confiabilidad del modelo para seleccionar acciones adecuadas ante variaciones de los objetivos del modelo (preferencias) y de las creencias del usuario (probabilidades *a priori*), los resultados obtenidos muestran un comportamiento confiable del modelo para seleccionar acciones óptimas. El tiempo de respuesta se evaluó considerando el uso de tres algoritmos de inferencia distintos y manteniendo fijo los parámetros de la red de decisión utilizada en cada escenario. Aunque la utilidad máxima esperada se incrementa de manera gradual al aumentar el número de etapas analizadas, también lo hace el tiempo en el que este valor es obtenido. Por lo tanto la RDD utilizada en cada escenario debe mantener un compromiso entre la mayor utilidad y el tiempo en el que se alcanza, de esta manera en este trabajo se utilizan redes con 5 y 4 etapas temporales para los escenarios de apoyo a discapacitados y videoconferencias respectivamente. Para esta evaluación nos apoyamos en la librería SMILE desarrollada en la Universidad de Pittsburgh.

En la siguiente fase de evaluación, se obtuvieron datos de la operación del sistema en los escenarios de videoconferencias y de apoyo a personas con problemas de memoria, proporcionados por participantes. En este caso, la toma de decisiones del modelo se comparó contra la toma de decisiones realizadas por una persona. En el escenario de videoconferencias se pidió la opinión de los participantes con respecto a los siguientes aspectos observados: **congruencia, sensibilidad y estabilidad**. A su vez, en el ambiente simulado de apoyo a discapacitados la evaluación fue referente a: **grado de especificidad de los mensajes, oportuno y efectividad**. La herramienta utilizada para apoyar la evaluación es el indicador de Likert y se manejaron 5 intervalos (1-5). La información proporcionada por el indicador de Likert muestra que el rendimiento del modelo (con respecto a la toma de decisiones) en estos escenarios es un poco menor (relativamente) a la realizada por una persona. Sin embargo, observando que la diferencia proporcionada por la métrica de Likert es menor al 20 por ciento, podemos concluir que el desempeño del modelo resulta satisfactorio y susceptible de ser mejorado.

# Capítulo 7

## Conclusiones

En este capítulo se van a mencionar las conclusiones obtenidas en este trabajo de tesis. En la Sección 7.1, se va a exponer un resumen del trabajo realizado. En la Sección 7.2, se van a mencionar las aportaciones realizadas por el trabajo desarrollado. Finalmente, en la Sección 7.3 se menciona el trabajo futuro.

### 7.1. Resumen

En esta tesis se propone un nuevo modelo computacional que integra técnicas de teoría de decisiones y visión computacional. El modelo desarrollado permite el reconocimiento visual del comportamiento humano al manipular objetos del entorno, y utilizar esta información como base para la toma de decisiones dinámicas. Este modelo puede ser implementado en una amplia gama de aplicaciones tales como: vigilancia y supervisión, videoconferencias y apoyo a personas discapacitadas, entre otras. El objetivo que se persigue en este trabajo es integrar técnicas de visión computacional y la teoría de decisiones para el desarrollo de sistemas que apoyen a las personas en diversas tareas. Las principales características del modelo desarrollado son:

1. **Fácil de especificar.** El modelo desarrollado es relativamente fácil de especificar con el fin de ser aplicado en distintos escenarios, para esto se encuentra estructurado en dos módulos separados:
  - Módulo de reconocimiento de gestos. Este módulo puede ser considerado como una interfaz de bajo nivel, es un sistema confiable para el reconocimiento de gestos manipulativos basado en los modelos ocultos de Markov (HMMs). Para facilitar el proceso de reconocimiento de gestos, este módulo utiliza información contextual relacionada con los objetos de interés presentes en el escenario en cuestión.
  - Módulo de toma de decisiones. Este módulo puede verse como una interfaz de toma de decisiones de alto nivel, el cual permite tomar decisiones a partir del análisis de un número finito de etapas futuras, basándose para ello en la información proporcionada por el módulo anterior.

Por lo tanto, para utilizar este modelo en diferentes escenarios, solamente se necesita realizar

modificaciones en el primer módulo para que reconozca los gestos en el nuevo escenario. El módulo de toma de decisiones prácticamente permanece igual.

2. **Permite tomar decisiones dinámicas.** El diseño de sistemas automatizados que tomen decisiones dinámicas es un problema difícil. El modelo que presentamos permite la toma de decisiones dinámicas a partir de considerar los siguientes aspectos:
  - Basa la toma de decisiones en el análisis de un número finito de etapas temporales, al final de las cuales, decide bajo un esquema de máxima utilidad la mejor alternativa.
  - Aplica un mecanismo sencillo para determinar el número de etapas temporales necesarias para seleccionar la acción en cada escenario.
  - Maneja un esquema simplificado de red de decisión, basada en una variable de estado, donde únicamente varía el número de valores dependiendo de la aplicación.
3. **Manejo de incertidumbre.** La característica de manejo de incertidumbre que tiene el modelo desarrollado en los módulos que lo forman, lo hacen adecuado para aplicarse en la mayoría de los ambientes reales.

El módulo de reconocimiento de gestos se basa en información de movimiento (trayectorias del centroide de la mano) y de contexto (color y posición relativa de objetos) para entrenar modelos ocultos de Markov (HMMs) y representar los distintos gestos en un escenario. La incorporación de información contextual durante la fase de aprendizaje proporciona resultados de reconocimiento promedio de gestos que van desde 94 % hasta 99,57 % en los escenarios utilizados. Esto representa un incremento significativo en el proceso de reconocimiento de gestos comparado al resultado obtenido cuando no se integra el contexto.

El modelo para la toma de decisiones fue implementado para su evaluación en dos distintos escenarios: Videoconferencias y Apoyo a personas para completar tareas. La evaluación realizada en ambos escenarios fue cuantitativa y en dos fases: (i) en la primera fase se realizó la evaluación del sistema considerando los criterios de tiempo de respuesta y selección de la mejor acción, (ii) en la segunda fase, se evaluó la eficiencia del modelo para seleccionar acciones en dos escenarios comparado contra la selección de acciones realizada por un humano en los mismos escenarios. Los resultados obtenidos en la primera fase demuestran que el modelo proporciona respuestas en un tiempo apropiado a las aplicaciones. Asimismo, se demuestra que el modelo es confiable al seleccionar la mejor alternativa ante ligeras variaciones en las condiciones de operación (objetivos del modelo y creencias hacia los estados). En la segunda fase de la evaluación se compara la eficiencia del modelo propuesto para seleccionar acciones contra las acciones seleccionadas por un humano en los mismos escenarios. Los resultados obtenidos en esta prueba se basaron en una encuesta realizada a un grupo de participantes. Los criterios de evaluación utilizados en este caso fueron: **sensibilidad, estabilidad y congruencia** los cuales fueron considerados en un escenario de videoconferencia, y **grado de especificación de los mensajes, efectivo y oportuno** para un escenario de apoyo a personas con problemas de memoria y/o discapacitados<sup>1</sup>. Los resultados obtenidos aplicando la escala de Likert [109] al evaluar los aspectos anteriores, indican una opinión favorable en la toma de decisiones realizada por el sistema propuesto en los escenarios utilizados.

Los resultados obtenidos de la evaluación indican que el sistema diseñado es capaz de tomar decisiones dinámicas en ambientes reales basado en el comportamiento humano.

---

<sup>1</sup>Este fue un escenario simulado, ya que las personas participantes no son discapacitadas y tampoco tienen problemas de memoria.

## 7.2. Aportaciones

Las principales contribuciones de esta tesis son las siguientes:

- Se aplican técnicas novedosas de modelos de color, tal como el uso de un nuevo modelo de color basado en los componentes RGY el cual resulta muy eficiente para reconocer regiones de piel en una secuencia de imágenes. Este modelo no se ha utilizado anteriormente y se incorpora en la etapa de detección y seguimiento de las partes de una persona en ambientes reales integrando el color de piel y movimiento.
- Se muestra un procedimiento para la selección de las características utilizadas en la etapa de reconocimiento de gestos manipulativos. Estas características, se basan en la trayectoria descrita por el centroide de la mano al realizar una actividad en un escenario conocido. Mediante un proceso exhaustivo de selección, discretización y evaluación se seleccionan las mejores características para reconocer un conjunto de gestos. El criterio de selección es el rendimiento de los modelos ocultos de Markov (HMMs) durante el proceso de reconocimiento de los gestos modelados. Este esquema resulta adecuado para extraer el menor conjunto de características que representan diversos gestos.
- Se incorpora una variación al algoritmo *CamShift* que permite un ajuste máximo en la ventana de seguimiento, el cual resulta apropiado para seguir partes de objetos. Esto se logra integrando al algoritmo de *CamShift* el filtro de Kalman con el fin de estimar la posición donde el algoritmo debe enfocar la búsqueda.
- Se propone un nuevo enfoque para el reconocimiento de gestos combinando información de movimiento con información de objetos presentes en un escenario. Este esquema, muestra la incorporación de información de alto nivel en los modelos ocultos de Markov (HMMs).
- Se propone en este trabajo un nuevo enfoque para la toma de decisiones dinámicas en ambientes reales aplicando redes de decisión dinámicas (RDDs). El modelo presentado permite utilizar información visual del comportamiento humano como base para la toma de decisiones. El empleo de esta técnica de reciente aparición en la toma de decisiones, aún no ha sido empleada para tomar decisiones dinámicas a partir de observar a una persona manipular objetos en un escenario. Sin embargo, ha demostrado éxito en otras aplicaciones, por lo que consideramos que este trabajo es una buena oportunidad para demostrar su eficiencia en nuevos escenarios. La estructura en módulos del modelo desarrollado, es con el fin de generar un esquema de especificación de parámetros sencilla para que el modelo pueda ser utilizado en diferentes escenarios con ligeras modificaciones.
- Se incorporan durante el desarrollo de este trabajo dos escenarios novedosos: Videoconferencias y Apoyo a personas para completar tareas. Estos escenarios no han sido utilizados anteriormente en el proceso de reconocimiento de gestos y toma de decisiones. Por lo tanto, se considera que la descripción realizada a los mismos, así como los resultados obtenidos pueden ser de utilidad a otros trabajos.

## 7.3. Trabajo futuro

Se considera la conveniencia de trabajar en los aspectos que se mencionan a continuación con el fin de mejorar el modelo computacional desarrollado.

- Es necesario continuar trabajando en la fase de reconocimiento de gestos, con el fin de ampliar la variedad de gestos manipulativos que puedan ser reconocidos. Para esto, se considera la incorporación de más partes del cuerpo de una persona, tales como: ambas manos y/o el rostro. Esto puede traer como consecuencia que el modelo cambie un poco, posiblemente se pase a utilizar una extensión de los modelos ocultos de Markov, tal como los modelos ocultos de Markov acoplados.
- Se requiere trabajar en métodos para aprender los parámetros (tablas de utilidad, matrices de transición) de la red de decisión dinámica. Actualmente estos parámetros se están determinando a través de observaciones. Sin embargo, es conveniente manejar un esquema de aprendizaje para que estos parámetros puedan ser especificados a través de datos. Asimismo, es necesario trabajar con el fin de incorporar el grafo de tareas y la especificación de los parámetros para que sean integrados en el modelo de una manera sencilla.
- Es necesario considerar nuevos algoritmos para mejorar la eficiencia en la evaluación de las redes de decisión dinámicas. Actualmente el modelo utiliza RDDs con un solo nodo aleatorio representando el estado del sistema bajo control, sin embargo al integrar más variables de estados al sistema se va a requerir de algoritmos eficientes que permitan obtener compromisos entre etapas analizadas y máximas utilidades en un tiempo apropiado a la aplicación.
- Asimismo, es conveniente probar el modelo computacional desarrollado en otros escenarios, con el fin de tener mayor información de su desempeño.

# Referencias

- [1] Pentland Alex, Nuria Oliver, and Rosario Barbara. Automatic recognition of human activities. *IEEE GRASP '04*, 987:456–467, 1987.
- [2] Anjum Ali and J. K. Aggarwal. Segmentation and recognition of continuous human activity. *IEEE Computer Society's Conference on Computer Vision and Pattern Recognition*, pages 28–35, 2001.
- [3] Nicolás Amézquita, René Alquezar, and Francesc Serratosa. Object recognition and tracking in video sequences: A new methodology. *Progress in Pattern Recognition, Image Analysis and Applications*, pages 481–490, 2006.
- [4] Hector Aviles Arriaga. Reconocimiento visual de ademanes aplicados a robots móviles. Master's thesis, Tec de Monterrey, Campus Cuernavaca, 2000. (In Spanish).
- [5] Douglas Ayers and Mubarak Shah. Monitoring human behavior from video taken in an office environment. *Image Vision Computing*, 19(12):833–846, 2001.
- [6] Cesar Bandera, Francisco J. Vico, Jose M. Bravo, and Mance E. Harmon. Residual q-learning applied to visual attention. *Proceedings of the Thirteenth International Conference on Machine Learning*, 1:3–6, 1996.
- [7] Thomas Bayes. An essay towards solving a problem in the doctrine of chances. *Philosophical Transactions of the Royal Society of London*, 53:370–418, 1763.
- [8] R. Bellman. Dynamic programming. *Princeton University Press*, 1957.
- [9] Michael J. Black and Allan D. Jepson. A probabilistic framework for matching temporal trajectories: Condensation-based recognition of gestures and expressions. *Proc. European Conference on Computer Vision*, pages 909–924, 1998.
- [10] A. F. Bobick. Computers seeing action. *British Machine Vision Conference, Edinburgh, Scotland*, 1:13–22, September 1996.
- [11] J. Boger, P. Poupart, J. Hoey, C. Boutilier, G. Fernie, and A. Mihailidis. A decision-theoretic approach to task assistance for persons with dementia. *Proceedings of the Nineteenth International Joint Conference on Artificial Intelligence, Edinburgh, Scotland*, pages 1293–1299, 2005.
- [12] C. Boutilier, T. Dean, and S. Hanks. Decision-theoretic planning: Structural assumptions and computational leverage. *Journal of Artificial Intelligence Research*, 11:1–94, 1999.
- [13] Craig Boutilier, Relu Patrascu, Pascal Poupart, and Dale Schuurmans. Regret-based elicitation in constraint-based decision problems. *Proceedings of AAAI - 05*, pages 204–211, 2005.

- [14] Craig Boutilier and David Poole. Computing optimal policies for partially observable decision process using compact representations. *Proceedings in Thirteenth National Conference on Artificial Intelligence (AAAI96)*, pages 1168–1175, 1996.
- [15] X. Boyen and D. Koller. Tractable inference for complex stochastic process. *In Proceedings of the Fourteenth Conference on Uncertainty Artificial Intelligence*, pages 1168–1175, 1996.
- [16] Gary R. Bradsky. Computer vision face tracking for use in a perceptual user interface. *Intel Technology journal Q2 '98*, pages 1–15, 1998.
- [17] Lee W. Campbell, David A. Becker, Ali Azarbayejani, Aaron F. Bobick, and Alex Pentland. Invariant features for 3-d gesture recognition. *In Proc. of the Intl. Workshop on Automatic Face and Gesture Recognition, Zurich*, 5:157–162, 1996.
- [18] P.S. Carbonetto. Using dynamic decision networks to make rational tutorial actions. *University of british Columbia, British Columbia*, pages 1–14, December 2002.
- [19] Anthony R. Cassandra, Leslie Pack Kaelbling, and Michael L. Littman. Acting optimally in partially observable stochastic domains. *In Proceedings of the Twelfth National Conference on Artificial Intelligence (AAAI-94)*, volume 2, pages 1023–1028, Seattle, Washington, USA, 1994. AAAI Press/MIT Press.
- [20] C. Conati, A. Gertner, K. Vanlehn, and M. Druzel. On-line student modeling for coached problem solving using bayesian networks. *6th International Conference on User Modeling (UM97)*, Chia Laguna, Sardinia, Italy, June 1997.
- [21] G. F. Cooper. The computational complexity of probabilistic inference using bayesian belief networks. *Artificial Intelligence*, 42:393–405, 1990.
- [22] G.F. Cooper. A method for using belief networks as influence diagrams. *In Proceedings of the Twelfth Conference on Uncertainty in Artificial Intelligence*, pages 55–63, 1988.
- [23] P. Dagum and M. Luby. Approximating probabilistic inference in bayesian belief networks is np-hard. *Artificial Intelligence*, 1:141–153, 1993.
- [24] Trevor Darrell and Alex Pentland. Active gesture recognition using learned visual attention. In David S. Touretzky, Michael C. Mozer, and Michael E. Hasselmo, editors, *Advances in Neural Information Processing Systems*, volume 8, pages 858–864. The MIT Press, 1996.
- [25] J. Davis and A. Bobick. The representation and recognition of action using temporal templates. *IEEE CVPR, Puerto Rico*, pages 928–934, Jun 1997.
- [26] T. Dean and K. Kanazawa. A model for reasoning about persistence and causation. *Computational Intelligence*, pages 142–150, 1989.
- [27] T. Dean and M. Wellman. Planning and control. *Morgan Kaufmann Publishers, San Mateo, CA*, 1991.
- [28] G.D. Finlayson, B. Schiele, and J.L. Crowley. Comprehensive colour image normalization. *Proceedings of the 5th European Conference on Computer Vision*, 1:475–490, June 1998.
- [29] W. Freeman and M. Roth. Orientation histogram for hand gesture recognition. *International Workshop on Automatic Face- and Gesture- Recognition, IEEE Computer Society, Zurich, Switzerland*, pages 296–301, 1995.

- [30] J. Frietsch. Vision-based recognition of gestures with context. *PhD Thesis, University of Bielefeld Vorgelegt von, Germany*, March 2003.
- [31] J. Fritsch, M. Kleinhagenbrock, S. Lang, T. Plotz, G. A. Fink, and G. Sagerer. Multimodal anchoring for human-robot-interaction. *In Proc. IEEE Int. Workshop on Robot and Human Interactive Communication (ROMAN)*, pages 337–343, 2003.
- [32] K. Fukunaga. Introduction to statistical pattern recognition. *Academic Press, Boston*, 1990.
- [33] R. Fung and K. Chang. Weighting and integrating evidence for stochastic simulation in bayesian networks. *In Uncertainty in Artificial Intelligence, Elsevier Science Publishing Company, Inc., New York, N. Y.*, pages 209–219, 1989.
- [34] B.V. Funt and G.D. Finlayson. Color constant color indexing. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 17:522–529, 1995.
- [35] Wyszecki G. and Styles W. Color science: Concepts and methods, quantitative data and formulae. *Second Edition. John Wiley and Sons, Inc., New York*, 1982.
- [36] Michael R. Garey and David S. Johnson. Computers and intractability a guide to the theory of np–completeness. *W.H Freeman and Company, New York*, 1979.
- [37] R.C Gonzalez and R. E. Woods. Digital image processing. *Adisson-Wesley*, 1992.
- [38] Robert M. Gray. Vector quantization. *IEEE ASSP Magazine*, 7:407–467, Apr 1984.
- [39] Milos Hauskretch. value function approximations for partially observable markov decision process. *journal of Artificial Intelligence Research*, 13:33–94, 2000.
- [40] M. Henrion. Propagation on uncertainty in bayesian networks by probabilistic logic sampling. *Uncertainty in Artificial Intelligence 2*, pages 149–163, 1988.
- [41] J. Hoey and J. Little. Decision theoretic modeling of human facial displays. *Technical Report TR-04-02 University of Toronto, Department of Computer Science*, 2004.
- [42] J. Hoey, P. Poupart, C. Boutilier, and Alex Mihailidis. Semi-supervised learning of a pomdp model of patient-caregiver interactions. *In Proceedings of the International Joint Conference on Autonomous Agents and Multi Agent Systems (AAMAS)*, pages 1–9, 2005.
- [43] Jesse. Hoey and James. J. Little. Value directed learning of gestures and facial displays. *IEEE Conference on Computer Vision and Pattern Recognition*, 2:1026–1033, 2004.
- [44] P. Hong, M. Turk, and T. S. Huang. Constructing finite state machines for fast gesture recognition. *Proc. Fourth IEEE International Conference and Gesture Recognition*, pages 691–694, March, Grenoble france 2000.
- [45] Ronald A. Howard and James E. Matheson. Influence diagrams. *In Ronald A. Howard and James E. Matheson, editors, The Principles and Applications of Decision Analysis*, pages 719–762, 1984.
- [46] C. Huang and A. Darwiche. Inference in belief networks: A procedural guide. *Intl. J. of Approximate Reasoning*, 1:1–158, 1994.
- [47] C. Huang and A. Darwiche. Inference in belief networks: A procedural guide. *International Journal of Approximate Reasoning*, 15:225–263, 1996.

- [48] T. Huang, D. Koller, J. Malik, G. Agasawara, B. Rao, S. Russell, and J. Weber. Automated symbolic traffic scene analysis using belief networks. *Proceedings of the Twelfth National Conference on Artificial Intelligence*, pages 966–972, 1994.
- [49] Bowen Hui and Craig Boutilier. Who’s asking for help? a bayesian approach to intelligent assistance. *Proceedings of the Nineteenth International Joint Conference on Artificial Intelligence*, pages 1293–1299, 2006.
- [50] M. isard and A. Blake. Condensation conditional density propagation for visual tracking. *International Journal of Computer Vision*, 29:5–28, 1998.
- [51] S. Jabri, Z. Duric, H. Wechsler, and A. Rosenfeld. Detection and location of people in video images using adaptive fusion of color and edge information. *IEEE Proceedings of the International Conference on Pattern Recognition*, 4:627–630, 2000.
- [52] M. J. Jones and J. M. Rehg. Statistical color models with application to skin detection. *In Proc. Computer Vision and Pattern Recognition, Ft. Collins, CO*, 1:274–280, January 1999.
- [53] L. P. Kaelbling, M. L. Littman, and A. W. Moore. Reinforcement learning: A survey. *Journal of Artificial Intelligence Research*, 4:237–285, 1996.
- [54] R. E. Kalman. A new approach to linear filtering and prediction problems. *Trans. ASME, J. Basic Engineering*, 82:35–94, 1960.
- [55] Y. Keselman and S. Dickinson. Bridging the representation gap between models and exemplars. *In IEEE Computer Society Workshop on Models versus Exemplars in Computer Vision*, pages 76–83, December 2001.
- [56] Jung-Bae Kim, Kwang-Yung Park, Won Hang, and Z. Zenn Bien. Continuous gesture recognition for korean-sign language based on fuzzy logic and hidden markov model. *IEEE Trans. on PAMI*, pages 1574–1579, 2002.
- [57] Gerald C. Kobylski. Optimizing time sensitive decisions in a networked battle command. *PhD. Thesis, Department of Mathematical Sciences, USMA*, 2005.
- [58] M. Kohler and S. Schroter. A survey of video-based gesture recognition - stereo and mono systems. *Technical Report 693, Informatik VII, University of Dortmund, Germany*, August 1998.
- [59] N. Krahnstover, M. Yeasin, and R. Sharma. Towards a unified framework for tracking and analysis of human motion. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, pages 47–54, 2001.
- [60] Morency L.-P., Sidner C., Lee C., and Trevor Darrell. The role of context of head gesture recognition. *Proceedings of the Twenty-first National Conference on Artificial Intelligence (AAAI), Boston, MA, USA*, pages 1–24, July 2006.
- [61] S. L. Lauritzen and D. J. Spiegelhalter. Local computation with probabilities on graphical structures and their applications to expert systems. *Journal of the Royal Society*, 50:157–224, 1988.
- [62] M. L. Littman, A. R. Cassandra, and L. P. Kaelbling. Learning policies for partially observable environments: Scaling up. *In Proceedings of the Twelfth International Conference on Machine Learning*, pages 362–370, 1995.

- [63] J. Lu, K. Plataniotis, and A. Venetsanopoulos. A comparative study of skin-color models. *Pattern Recognition Letter* 26, pages 181–191, 2005.
- [64] Anant Madabhushi and J. K. Aggarwal. A bayesian approach to to human activity recognition. *15th International Conference on Computer Vision*, pages 698–701, June 2000.
- [65] P. Magni. A new approach to optimal dynamic therapy planning. *In Transforming Health Care Through Informatics: Proceedings of the 1999 AMIA Annual Symposium*, pages 1–5, 1999.
- [66] Richard Mann and Allan D. Jepson. Towards the computational perception of action. In *CVPR*, pages 794–799, 1998.
- [67] Miriam Martínez and Luis E. Sucar. Learning and optimal naive bayes classifier. *36vo Congreso de Investigacion y Desarrollo del Tecnológico de Monterrey: Impulsando la Economía Basada en Conocimiento*, 2006.
- [68] James A. Matheson. Using influence diagrams to value information and control. *Influence Diagrams, Belief Nets and Decision Analysis. Chapter 2*, John Wiley and Sons, 1990.
- [69] B. Maxwell and Steven A. Shafer. Segmentation and interpretation of multicolored objects with highlights. *Computer Vision and Image Understanding*, 77:1–24, 2000.
- [70] A. Mihailidis, B. Carmichael, and J. Boger. The use of computer vision in an intelligent environment to support aging-inplace, safety, and independence in the home. *IEEE Transaction on Information Technology in Biomedicine*, pages 1–11, 2004.
- [71] Byung-Woo Min, Ho-Sub Yoon, Jung Soh, and Young-Kyu Yang. Visual gesture recognition for real-time edition system. *Proc. International Workshop on Automatic Face and Gesture Recognition*, pages 982–984, 1999.
- [72] J. Miura and K. Ikeuchi. Task-oriented generation of visual sensing strategies in assembly tasks. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 20(2):126–137, 1998.
- [73] Jose Antonio Montero and Luis Enrique Sucar. Context-based gesture recognition. *11th Iberoamerican Congress on Pattern Recognition CIARP’2006*, pages 764–773, November 14-17, Cancun, Mex. 2006.
- [74] Jose Antonio Montero and Luis Enrique Sucar. A decision-theoretic assistant based on gesture recognition. *5th Mexican International Conference on Artificial Intelligence MICA I 2006*, pages 78–87, November 14-17, Apizaco, Mex. 2006.
- [75] Jose Antonio Montero and Luis Enrique sucar. A decision-theoretic video conference system based on gesture recognition. *7th IEEE International Conference Automatic Face and Gesture Recognition, FG2006*, pages 387–392, 2006.
- [76] Darnell J. Moore, Irfan A. Essa, and Monson H. Hayes. Exploiting human actions and object context for recognition tasks. *Proc. IEEE of the 7th International Conference on Computer Vision*, 1:80–86, Sep 2000.
- [77] L. P. Morency, C. Sidner, C. Lee, and T. Darrell. Contextual recognition of head gestures. *Proceedings of the International Conference on Multi-modal Interfaces*, October 2005.

- [78] Louis-Philippe Morency and Trevor Darrell. Head gesture recognition in intelligent interfaces: The role of context in improving recognition. *Proceedings of the 11th International Conference on Intelligent User Interfaces (IUI'06), Sydney, Australia*, pages 32–38, January 2006.
- [79] R. C. Murray. An evaluation of decision-theoretic tutorial action selection. *PhD dissertation, University of Pittsburgh, Intelligent Systems Program*, 2005. <http://etd.library.pitt.edu/ETD/available/etd-08182005-131235/>.
- [80] R.C. Murray and K. VanLehn. Dt tutor: A decision-theoretic, dynamic approach for optimal selection of tutorial actions. *5th International Conference of Intelligent Tutoring Systems ITS 2000*, pages 153–162, 2000.
- [81] George Nakos and David Joyner. Linear algebra with applications. *Brooks Cole Publishing, an ITP Company*, 1998.
- [82] T. Olson and F. Brill. Moving object detection and event recognition algorithms for smart cameras. *Proc. DARPA Image Understanding Workshop*, pages 159–175, 1997.
- [83] N. Otsu. A threshold selection method from gray-level histograms. *IEEE, Trans. Sys, Man, and Cybernetics*, 1:62–66, Jan 1979.
- [84] Vasu Parameswaran and Rama Chellappa. Human action-recognition using mutual invariants. *Computer Vision and Image Understanding*, 98(2):295–325, 2005.
- [85] G. T. Park, Z. Bien, C-S Lee, W. Jang, and J. H. Kim. Real-time recognition system of Korean sign language based on elementary components. *Proceedings of the Sixth IEEE International Conference on Fuzzy Systems*, 3:1463–1468, 1997.
- [86] V. Pavlovic, R. Sharma, and T. Huang. Visual interpretation of hand gestures for human-computer interaction: A review. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 19:677–695, July 1997.
- [87] J. Pearl. Probabilistic reasoning in intelligent systems: Networks of plausible inference. *Morgan Kaufmann, San Mateo California*, 1988.
- [88] J. Pearl. Causality: Models, reasoning and inference. *Cambridge Univ. Press*, 2000.
- [89] P. Peixoto, J. Batista, and H. Araujo. Real-time human activity monitoring exploring multiple vision sensors. *Proc. 7th Int. Symposium on Robotics and Autonomous Systems*, 35:221–228, June 2001.
- [90] Petra Perner. Case-based object recognition with application to biological images. *Progress in Pattern Recognition, Image Analysis and Applications*, pages 27–37, 2006.
- [91] S. L. Phung, Bouzerdoum, and A. Chai. Skin segmentation using color pixel classification: Analysis and comparison. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 27:148–154, 2005.
- [92] A. Psarrou, S. Gong, and M. Walter. Recognition of human gestures and behaviour based on motion trajectories. *Image and Vision Computing*, 20:349–358, 2002.
- [93] M. L. Puterman. Markov decision process discrete stochastic dynamic programming. *New York, New York: John Wiley Sons, Inc.*, 1994.

- [94] D. L. Quan. Gesture recognition with a data glove. *IEEE Proc. National Aerospace and Electronics Conf.*, 2, 1990.
- [95] L. R. Rabiner. A tutorial on hidden markov models and selected applications in speech recognition. *Proceedings of the IEEE*, 77(2):257–286, February 1989.
- [96] L. R. Rabiner and B. H. Huang. An introduction to hidden markov models. *IEEE ASSP Magazine*, 3(1):4–16, 1986.
- [97] Cen Rao and Mubarak Shah. View-invariant representation and recognition of actions. *International Journal of Computer Vision*, 1:55–61, 2002.
- [98] Haibing Ren and Guangyou Xu. Human action recognition in smart classroom. *Proc. of the Fifth IEEE International Conference on Automatic Face and Gesture Recognition*, 5:54–60, 2002.
- [99] M. D. Resnik. Choices: An introduction to decision theory. *University of Minnesota Press*, 1987.
- [100] J. Reye. Two-phase updating of student models based on dynamic belief networks. *4th International Conference on Intelligent Tutoring Systems (ITS '98), San Antonio Texas, USA*, pages 274–283, 1998.
- [101] S. Russell and P. Norvig. Artificial intelligence: A modern approach. *Prentice Hall, Englewood Cliffs, NJ, second edition*, 2002.
- [102] Shatcher and Peot. Decision making using probabilistic inference methods. *In Proc. of 8th Conference on Uncertainty in Artificial Intelligence*, pages 276–283, 1992.
- [103] Yaser Sheikh and Mubarak Shah. Exploring the space of an action for human action recognition. *International Conference on Computer Vision ICCV '05*, 1:144–149, October 2005.
- [104] J. Siskind. Visual event perception. (*In K. Ikeuchi M. Veloso Eds.*), *Symbolic Visual Learning. New York, NY: Oxford University Press*, 1997.
- [105] E. J. Sondik. The optimal control of partially observable markov process over the infinite horizon. *:Discounted costs, Op. Res.*, pages 282–304, 1978.
- [106] T. Starner. Visual recognition of american sign language using hidden markov models. *Masters's thesis, MIT Media Laboratory*, Feb 1995.
- [107] M. J. Swain and D. H. Ballard. Color indexing. *International Journal of Computer Vision*, pages 11–32, 1991.
- [108] M. Thonnat and N. rota. Video sequence interpretation for visual surveillance. *Third International Workshop on Cooperative Distributed Vision*, pages 1–9, November 2000.
- [109] W. Torgerson. Theory and methods of scaling. *New York, Wiley*, 1965.
- [110] J. Triesch and C. von der Malsburg. A gesture interface for human-robot-interaction. *In FG98, IEEE Third International Conference on Automatic Face and Gesture Recognition, April 14–16 in Nara, Japan*, pages 546–551. IEEE, 1998.

- [111] Mike Tsykin and Christopher D. Landshaw. End-to-end response time and beyond: direct measurement of service levels. *Work sponsored by Fujitsu Australia Limited*, 1998. <http://www.fujitsu.com/downloads/AU/Endtoendresponsetimeandbeyond.pdf>.
- [112] Eric Tuttle and Zoubin Ghahramani. Propagating uncertainty in pomdp value iteration with gaussian processes. *Technical Report, University College London*, November 2004.
- [113] Jose Antonio Montero V. and Luis Enrique Sucar S. Feature selection for visual gesture recognition using hidden markov models. *Fifth Mexican International Conference on Computer Science*, 1:196–203, 2004.
- [114] P. Varakantham, R. Maheswaran, and M. Tambe. Exploiting belief bounds: Practical pomdps for personal assistant agents. *In Proceedings of the International Joint Conference on Autonomous Agents and Multi Agent Systems*, pages 978–985, july 2005.
- [115] Michael Villamizar, Alberto Sanfeliu, and Juan Andrade. Orientation invariante features for multiclass object recognition. *Progress in Pattern Recognition, Image Analysis and Applications*, pages 655–664, November 2006.
- [116] C. von Hardenberg and F. Berard. Bare-hand human-computer interaction. *In ACM workshop on Perceptive User Interfaces (PUI 2001), Orlando, Florida*, pages 1–8, 2001.
- [117] Sy Bor Wang, Ariadna Quattoni, Louis-Philippe Morency, David Demirdjian, and Trevor Darrell. Hidden conditional random fields for gesture recognition. *Proceedings IEEE Conference on Computer Vision and Pattern Recognition (CVPR'06)*, 2:1521–1527, June 2006.
- [118] J. Williams, P. Poupart, and S. Young. Using factored markov decision processes with continuous observations for dialogue management. *Technical Report CUED/F-INFEG/TR.520, Cambridge University, Engineering Department*, 2005.
- [119] Y. Wu and T. S. Huang. Vision-based gesture recognition: A review. *Proceedings of the International Gesture Workshop on Gesture-Based Communication in Human-Computer Interaction, London UK*, pages 103–115, 1999.
- [120] Y. Xiang and C. Ye. A simple method to evaluate influence diagrams. *Third International Conference on Cognitive Science*, pages 1–6, 2001.
- [121] J. Yamato, J. Ohya, and K. Ishii. Recognizing human action in time-sequential images using hidden markov models. *IEEE Conference on Computer Vision and Pättern Recognition*, pages 379–385, June 15-18 1992.
- [122] Jie Yang, Yangshen Xu, and Chiu S. Chen. Human action learning via hidden markov model. *IEEE Transactions on Systems Man and Cybernetics -Part A:Systems and Humans*, 27:34–44, Jan 1997.
- [123] M. Yang, N. Ahuja, and M. Tabb. Extraction of 2d motion trajectories and its application to hand gesture recognition. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 8:1061–1074, 2002.
- [124] M. H. Yang, D. J. Kriegman, and N. Ahuja. Detecting faces in images: A survey. *IEEE Trans. Pattern Analysis and Machine Intelligence*, 24:34–58, 2002.

- [125] Ho-Sub Yoon, Jung SOH, Byung-Woo Ming, and Hyung Seung YANG. Recognition of alphabetical hand gestures using hidden markov model. *IEEE Trans. Fundamentals*, 82(7):1358–1366, Jul 1999.
- [126] N. L. Zhang and W. Liu. Planning in stochastic domains: Problem characteristics and approximation. *Technical Report HKUST-CS96-31, Hong Kong University of Science and Technology*, 1996.

# Apéndice A

## Selección de características

En este anexo se muestra el complemento a la Sección 4.3, relacionado con el proceso de selección y extracción de las características manejadas para la clasificación de los gestos manipulativos utilizados en este trabajo y representados por modelos ocultos de Markov (HMMs). Durante el proceso para la selección de características, se pretende elegir atributos que sean representativos para una aplicación y lograr el máximo rendimiento con el mínimo esfuerzo. El resultado de este proceso es:

- **Menos datos** → los algoritmos pueden aprender más rápidamente.
- **Mayor exactitud** → el clasificador generaliza mejor.
- **Resultados más simples** → más fácil de entender.

Asimismo, este proceso persigue los siguientes objetivos:

- reducir la complejidad del clasificador y su implementación en hardware/software.
- compresión de información (eliminar características redundantes e irrelevantes).
- reducir el costo de medición al disminuir el número de características.
- proveer una mejor clasificación debido a efectos por tamaño finito de la muestra.

Actualmente, la selección de características es un problema vigente, es decir, no existe un método general que permita su selección para cualquier problema de clasificación. Como se mencionó en el Capítulo 4 (Sección 4.3), en este trabajo se utilizan características basadas en trayectoria, por ser las que más se adaptan a las aplicaciones manejadas. El procedimiento aplicado para la selección de las mismas, se muestra en el diagrama de flujo indicado en la Figura A.1. El conjunto de características inicialmente seleccionadas (conjunto original en el diagrama) fueron las siguientes: (a) magnitud ( $\rho$ ) en coordenadas polares, (b) orientación ( $\phi$ ) en coordenadas polares, (c) posición  $x$  en coordenadas cartesianas, (d) posición  $y$  en coordenadas cartesianas, (e) velocidad ( $v$ ) en coordenadas cartesianas y (f) código de cadena ( $CC$ ).

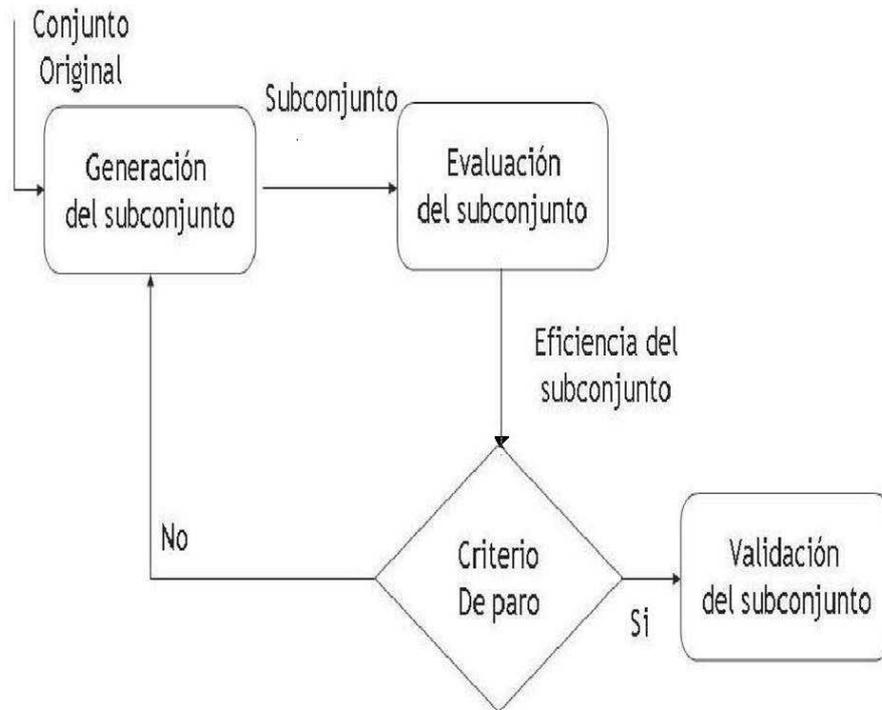


Figura A.1: Diagrama de flujo en que se basa el proceso para la selección de características utilizado en este trabajo.

Las características mencionadas van a ser combinadas de forma exhaustiva. Esto, da como resultado la generación de subconjuntos que van a ser verificados de manera individual. La Tabla A.1, muestra los subconjuntos que fueron evaluados durante el proceso para seleccionar las características utilizadas. Se evaluaron 63 combinaciones (tal como aparecen en la Tabla A.1), el criterio de paro, aplicado para seleccionar el subconjunto que mejor discrimine los gestos manipulativos, se basó en la eficiencia obtenida por los HMMs durante esta fase. Por lo tanto, el rendimiento de los HMMs durante el proceso de reconocimiento de los gestos, es el que determina la validación del subconjunto de características seleccionado. Las variables que aparecen en la Tabla A.1, se encuentran normalizadas en el intervalo 0–1, enseguida se muestra como se obtiene la normalización.

### Normalización de características

En la Sección 4.3 del Capítulo 4, se muestra el proceso de normalización de las características que ofrecieron el mayor porcentaje en el reconocimiento de los gestos manipulativos. En este párrafo, se va a indicar la forma de normalizar a las características restantes (posición  $(x, y)$  en coordenadas cartesianas y el código de cadena  $(CC)$ ). En la Figura A.2, se muestra la característica sin normalizar correspondiente a la variable: código de cadena  $(CC)$ . La normalización del código de cadena se realiza con la siguiente expresión:

$$cc = \frac{CC}{2\pi} \tag{A.1}$$

Donde el valor de la variable  $\pi$  se maneja en radianes. En este trabajo, los valores para esta característica se manejaron en un rango discretizado comprendido entre 0 y 15.

Tabla A.1: subconjuntos de características formados durante el proceso para seleccionar las características utilizadas en este trabajo.

Subconjuntos con 6 variables	Subconjuntos con 5 variables	Subconjuntos con 4 variables	Subconjuntos con 3 variables	Subconjuntos con 2 variables	Subconjuntos con 1 variable
[x, y, ρ, φ, v, cc]	[x, y, ρ, φ, v] [x, y, ρ, φ, cc] [x, y, ρ, v, cc] [x, y, φ, v, cc] [x, ρ, φ, v, cc] [y, ρ, φ, v, cc]	[x, y, ρ, φ] [x, y, ρ, v] [x, y, ρ, cc] [x, y, φ, v] [x, y, φ, cc] [x, y, v, cc] [x, v, ρ, φ] [x, cc, ρ, φ] [x, v, cc, ρ] [x, v, cc, φ] [y, v, ρ, φ] [y, cc, ρ, φ] [y, v, cc, ρ] [y, v, cc, φ] [v, cc, ρ, φ]	[x, y, ρ] [x, y, φ] [x, y, v] [x, y, cc] [x, ρ, φ] [x, ρ, v] [x, ρ, cc] [x, φ, v] [x, φ, cc] [x, v, cc] [y, ρ, φ] [y, ρ, v] [y, ρ, cc] [y, φ, v] [y, φ, cc] [y, v, cc] [ρ, φ, v] [ρ, φ, cc] [ρ, v, cc] [φ, v, cc]	[x, y] [x, ρ] [x, φ] [x, v] [x, cc] [y, ρ] [y, φ] [y, v] [y, cc] [ρ, φ] [ρ, v] [ρ, cc] [φ, v] [φ, cc] [v, cc]	[x] [y] [ρ] [φ] [v] [cc]

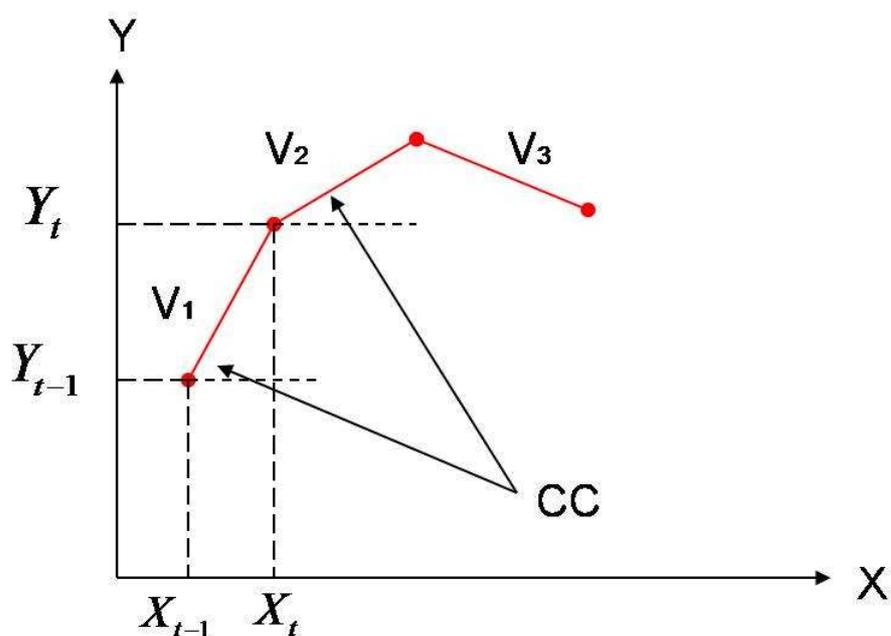


Figura A.2: Ilustración del código de cadena (CC) en un sistema de coordenadas cartesianas. Esta característica, indica la forma que sigue la trayectoria de un gesto. Esta trayectoria, se obtiene conectando la secuencia de los puntos descritos por el centroide de la mano al realizar un gesto manipulativo.

---

Para normalizar las características correspondientes a la posición en coordenadas cartesianas se procede como sigue: se toma como referencia el origen de la imagen y se calcula la magnitud del punto máximo descrito por el centroide de la mano en el eje de las  $\mathbf{X}$ 's, ( $X_{max}$ ), con la siguiente expresión:

$$X_{max} = \max_{t=1}^n (X_t) \quad (\text{A.2})$$

Donde,  $n$  se refiere al número de puntos que forman la trayectoria descrita por el centroide de la mano durante un gesto manipulativo. Se hace el mismo cálculo para obtener el mayor valor sobre el eje de las  $\mathbf{Y}$ 's ( $Y_{max}$ ), con la siguiente expresión:

$$Y_{max} = \max_{t=1}^n (Y_t) \quad (\text{A.3})$$

Una vez que se tienen los valores anteriores, se procede a normalizar estas características aplicando las siguientes expresiones:

$$x_t = \frac{X_t}{X_{max}} \quad (\text{A.4})$$

$$y_t = \frac{Y_t}{Y_{max}} \quad (\text{A.5})$$

Donde,  $x_t$  y  $y_t$ , representan los valores normalizados obtenidos para las variables de posición en un rango comprendido ente 0 y 1.

### **Evaluación de los subconjuntos de características**

En esta sección, se va a mostrar el procedimiento indicado en la Figura A.1, utilizando los subconjuntos mostrados en la Tabla A.1, con el fin de seleccionar las características que mejor clasifiquen los gestos manipulativos empleados en este trabajo. Los porcentajes de reconocimiento mostrados en las ilustraciones, son obtenidos como se indicó en el Capítulo 4, es decir, son promedios calculados al repetir secuencias de datos de entrenamiento y de evaluación.

El procedimiento que realiza la evaluación es el siguiente:

1. Para cada tamaño del alfabeto  $M$  hacer:
  - Para cada número de estados ( $N$ ) del modelo HMM hacer:
  - Para cada una de las combinaciones de las características hacer:
2. Aplicar *K-Means* sobre todo el conjunto de datos de las trayectorias y obtener secuencias de  $M$  posibles símbolos discretos para cada trayectoria de cada gesto.

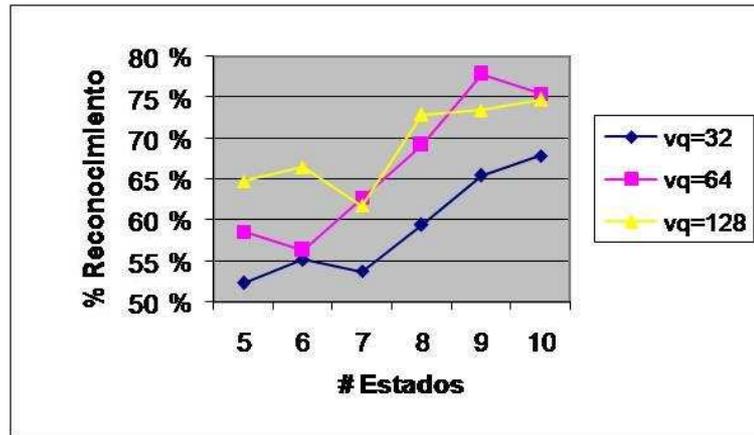


Figura A.3: Porcentaje de reconocimiento obtenido por los HMMs, cuando se utiliza el primer subconjunto de características indicado en la Tabla A.1, es decir, todas las características. Asimismo, se muestra la variación del número de estados ( $N$ ) y el tamaño del libro de códigos.

3. Para cada secuencia de gesto generar y entrenar un modelo HMM con  $N$  estados y  $M$  posibles símbolos de observación, con sus respectivas secuencias de observaciones discretas de las trayectorias.
4. Para cada gesto, evaluar el modelo HMM con datos de prueba y obtener porcentaje de reconocimiento (validación de las características).

A continuación se explican los resultados obtenidos durante el procedimiento de evaluación.

La Figura A.3, muestra el porcentaje de reconocimiento promedio obtenido por los HMMs al manejar el primer subconjunto de características. De acuerdo con la Tabla A.1, este subconjunto está formado por la combinación de todas las características seleccionadas de manera inicial (columna 1 de la Tabla A.1). El máximo porcentaje de reconocimiento alcanzado bajo estas condiciones es de 77,57%, y se obtiene al manejar un libro de códigos con 64 símbolos observables, y modelos HMMs con 9 estados ocultos.

La Figura A.4, ilustra el porcentaje de reconocimiento alcanzado por los modelos ocultos de Markov (HMMs), al utilizar como única característica la posición  $x$ , aplicando el sistema de coordenadas cartesianas. Se observa, que el mayor porcentaje de reconocimiento (56%) se obtiene al manejar 128 símbolos observables y 9 estados ocultos

Asimismo, las Figuras A.5 y A.6, indican el porcentaje de reconocimiento promedio alcanzado por los HMMs, cuando se aplican como características la posición ( $y$ ) en el sistema de coordenadas cartesiano, y el código de cadenas respectivamente. Los mayores porcentajes de reconocimiento obtenidos en cada caso son de 50% y 58%, alcanzados con 64 y 128 símbolos de observación. En ambos casos, se utilizaron HMMs con 10 estados ocultos.

Se observa en la Figura A.7, el porcentaje de reconocimiento promedio, obtenido al usar como característica la orientación  $\phi$  en coordenadas polares. Al igual que en los casos mostrados con anterioridad, este porcentaje se muestra en función de variar el número de estados  $N$  del HMM y el alfabeto utilizado por el mismo. En este caso, se observa que el porcentaje de reconocimiento máximo (96%) se obtiene cuando el número de estados de los modelos HMMs es de 7 y el tamaño del libro de códigos es de 32.

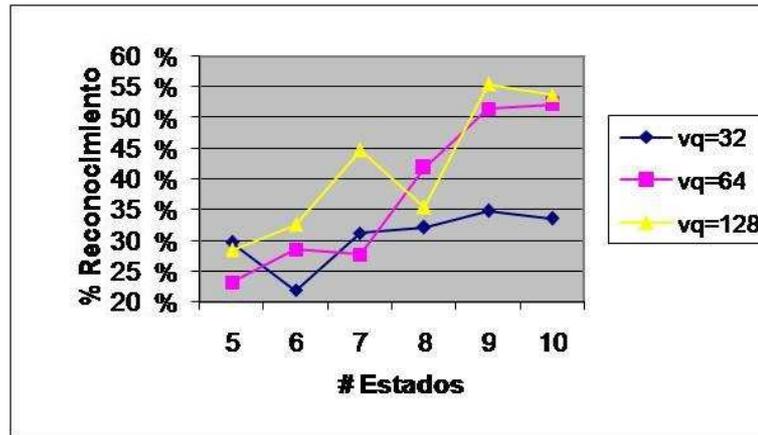


Figura A.4: Porcentaje de reconocimiento obtenido por los HMMs, cuando se utiliza como característica la posición  $x$ , en el eje de coordenadas cartesianas. Se muestra el reconocimiento al variar el número de estados ( $N$ ) ocultos del modelo y el tamaño del libro de códigos.

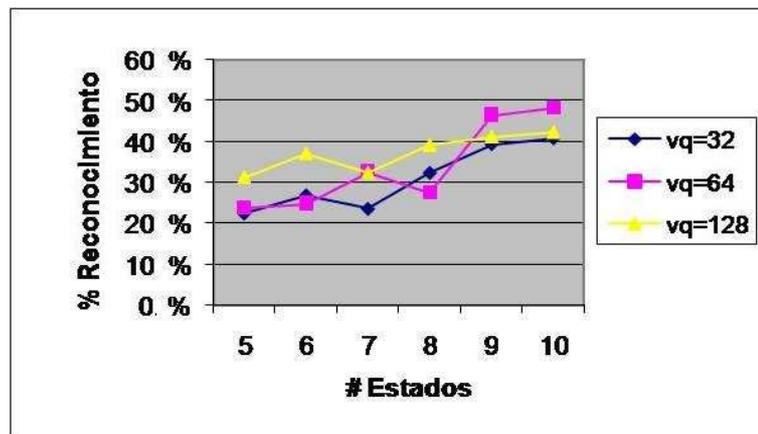


Figura A.5: Porcentaje de reconocimiento obtenido por los HMMs, cuando se utiliza como característica la posición  $y$ , en el eje de coordenadas cartesianas. Se muestra el reconocimiento al variar el número de estados ( $N$ ) ocultos del modelo y el tamaño del libro de códigos.

Se muestra en la Figura A.8, el porcentaje de reconocimiento del conjunto de los gestos modelados, cuando la característica usada es la magnitud ( $\rho$ ) en coordenadas polares. El número de estados del HMM varía de 5 a 10, y el tamaño del libro de códigos (símbolos observables generados por los estados ocultos) toma los valores de 16, 32, y 64. Se observa que el mayor porcentaje de reconocimiento (72%), se obtiene para modelos de 7 estados y un tamaño de libro de código de 16. Asimismo, al utilizar de manera individual como característica la velocidad ( $v$ ) en coordenadas cartesianas, se obtiene un porcentaje máximo de reconocimiento de 77%. Este porcentaje en el reconocimiento, se alcanza con modelos HMMs con 7 estados ocultos y un libro de códigos de tamaño 64, esto se ilustra en la Figura A.9.

Al llevar a cabo la evaluación de las características de manera individual, y aplicadas con el fin de clasificar un grupo de gestos manipulativos realizados en un ambiente de oficina, se obtienen las siguientes conclusiones:

- El grupo de características formado por: (i) posición  $x$ , (ii) posición  $y$ , y (iii) código de cadena

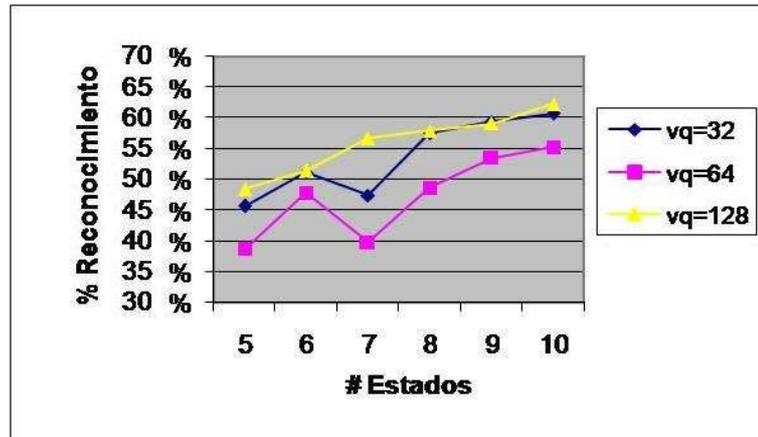


Figura A.6: Porcentaje de reconocimiento obtenido por los HMMs, cuando se utiliza como característica el código de cadena ( $cc$ ). Se muestra el reconocimiento alcanzado al variar el número de estados ( $N$ ) ocultos del modelo y el tamaño del libro de códigos.

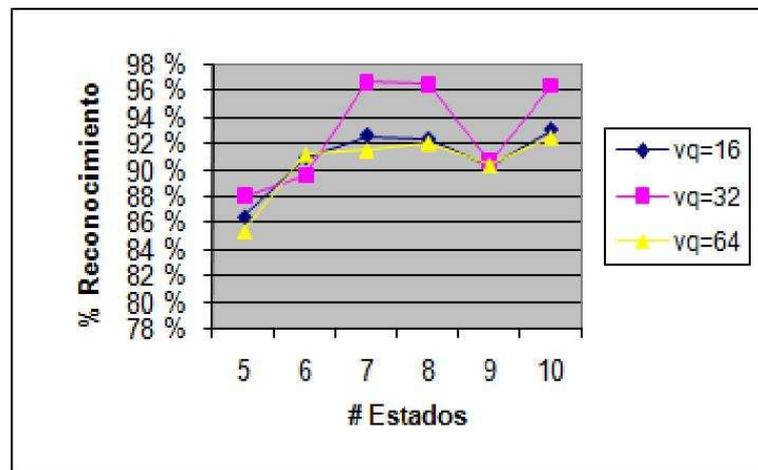


Figura A.7: Reconocimiento promedio obtenido por los modelos ocultos de Markov al utilizar como característica la orientación ( $\phi$ ) en coordenada polar.

( $cc$ ), al ser evaluados de manera individual dieron como resultado un bajo rendimiento ( $< 60\%$ ) en el proceso de reconocimiento de gestos.

- El grupo de características integrado por: (i) la magnitud ( $\rho$ ) en coordenada polar, (ii) orientación ( $\phi$ ) en coordenada polar, y (iii) la velocidad ( $v$ ) en coordenadas cartesianas, al ser evaluados de manera individual ofrecieron un buen rendimiento ( $> 70\%$ ) en el proceso de reconocimiento de gestos.

Por lo tanto, a partir de este primer análisis, se determina continuar con la evaluación de los subconjuntos formados solamente por las tres características que ofrecieron los mayores porcentajes durante el proceso de reconocimiento. Posteriormente, se verificará si el uso de las características que dieron bajo rendimiento, apoya el proceso de clasificación al ser integrada en uno de los subconjuntos.

En la Figura A.10, se muestra el porcentaje de reconocimiento promedio alcanzado por el modelo desarrollado en este trabajo, al emplear el subconjunto de características integrado por: la orientación ( $\phi$ ) en coordenada polar y la velocidad  $v$  en coordenadas cartesianas. El libro de códigos utilizado durante esta evaluación, muestra una variación en tamaño de 32, 64, y 128 símbolos repre-

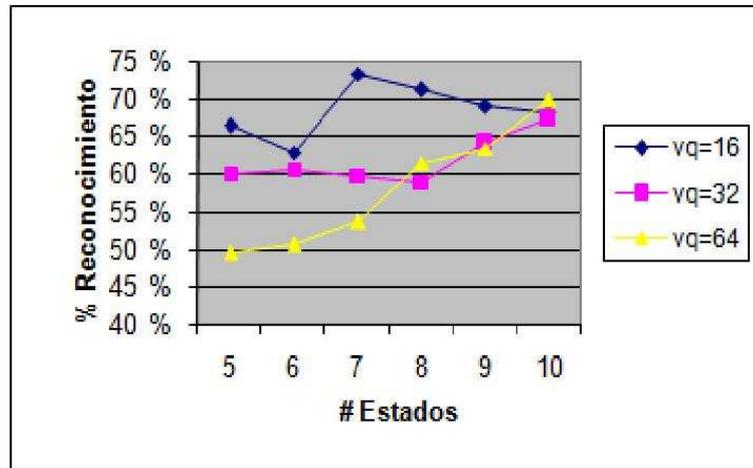


Figura A.8: Porcentaje de reconocimiento obtenido por los HMMs utilizados al emplear como característica la magnitud polar ( $\rho$ ), al variar el número de estados ocultos ( $N$ ), así como el número de símbolos observables.

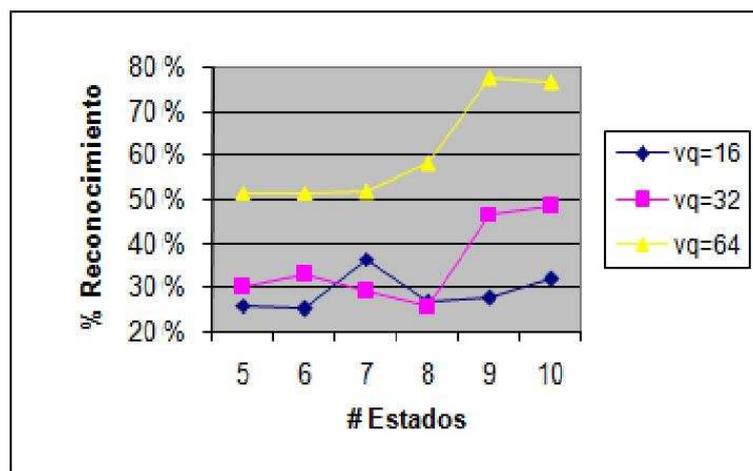


Figura A.9: Reconocimiento obtenido al emplear como característica la velocidad ( $v$ ) en coordenadas cartesianas. El porcentaje de reconocimiento se muestra en función del número de estados ocultos utilizados por el modelo y tamaño del libro de códigos.

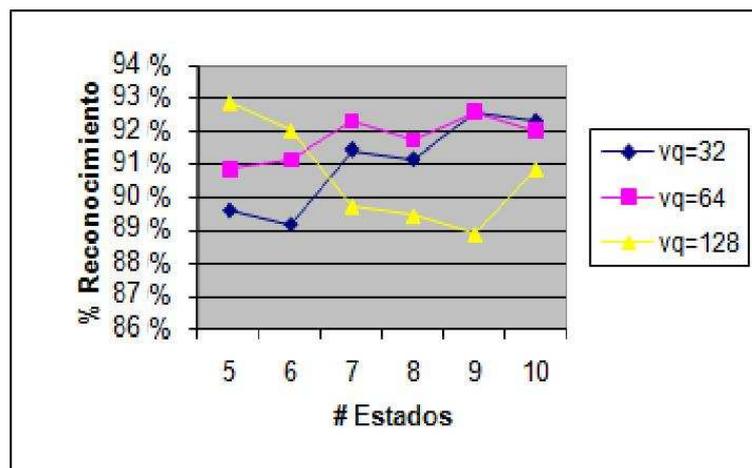


Figura A.10: Porcentaje de reconocimiento obtenido al emplear el subconjunto de características formado por la orientación ( $\phi$ ) en coordenada polar y la velocidad ( $v$ ) en coordenadas cartesianas, al variar el número de estados ocultos y tamaño del libro de códigos.

sentando la secuencia de observación. El mayor porcentaje de reconocimiento se obtiene con modelos HMMs que manejan 5 estados ocultos y un alfabeto integrado por 128 símbolos de observación. En este caso, el reconocimiento promedio alcanzado bajo las condiciones mencionadas fue de 93 %.

Al continuar con el proceso de combinar las características en subconjuntos formados por dos de las mismas, se ilustra en las Figuras A.11 y A.12, se muestran los porcentajes de reconocimiento promedio alcanzados cuando se combinan las características de magnitud  $\rho$  y orientación  $\phi$  en coordenadas polares, y magnitud  $\rho$  polar con la velocidad  $v$  en coordenadas cartesianas.

En ambos casos, las pruebas experimentales se realizan variando el tamaño del libro de códigos con 32, 64, y 128 símbolos, que representan la secuencia de observación. De igual manera, el número de estados de los HMMs utilizados en el proceso de reconocimiento aplicando el algoritmo de Viterbi, varían de 5 a 10 estados. El mayor porcentaje de reconocimiento obtenido al combinar las características  $\rho\phi$ , fue de 97% con modelos de 10 estados, y un tamaño de libro de códigos de 64 símbolos. Por su parte, el mayor porcentaje de reconocimiento al aplicar la combinación  $\rho - v$  se alcanza para modelos HMM con 9 estados ocultos y 64 símbolos observables. El porcentaje de reconocimiento alcanzado en este caso fue de 79 %.

En la Figura A.13, se observa el porcentaje del reconocimiento promedio, obtenido cuando se utiliza el subconjunto de características formado por: (i) la magnitud polar ( $\rho$ ), (ii) la orientación polar ( $\phi$ ) y (iii) la velocidad ( $v$ ) en coordenadas cartesianas. El porcentaje alcanzado durante el proceso de reconocimiento manejando este subconjunto de características fue de 88 %, este porcentaje fue alcanzado con HMMs de 10 estados y 128 símbolos observables.

Finalmente, en la Figura A.14, se ilustra el reconocimiento promedio obtenido al utilizar como características el subconjunto formado por la magnitud  $\rho$  y orientación  $\phi$  en coordenadas polares y la posición  $x$  en coordenadas cartesianas. El mayor porcentaje de reconocimiento alcanzado al emplear el subconjunto mencionado ocurre con modelos HMMs que manejan 10 estados ocultos y 128 símbolos observables. El porcentaje alcanzado fue de 77,85 %.

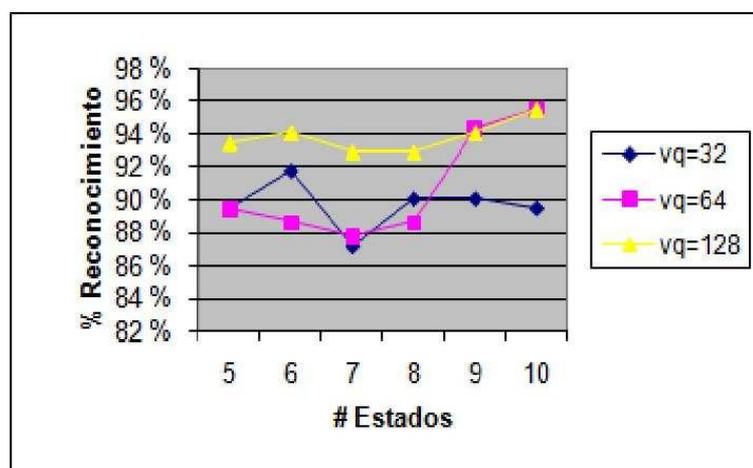


Figura A.11: Ilustración del porcentaje de reconocimiento promedio, obtenido por el modelo utilizado al emplear como característica el subconjunto formado por: la magnitud ( $\rho$ ) y la orientación ( $\phi$ ) en coordenadas polares. Este reconocimiento se muestra al variar el número de estados ocultos y símbolos observables utilizados por los HMMs empleados.

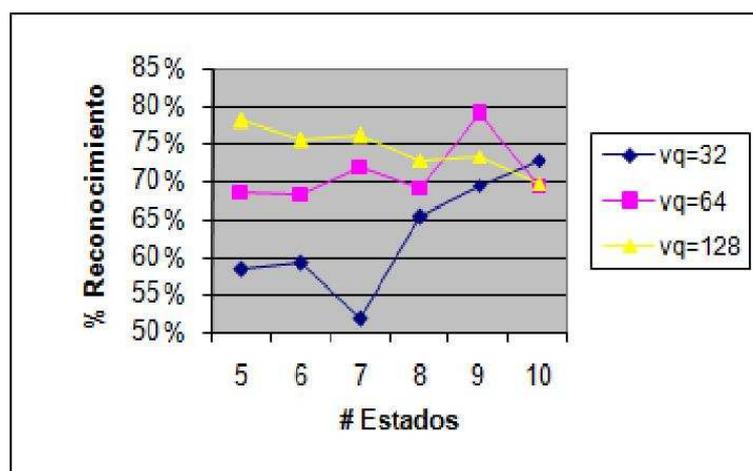


Figura A.12: Reconocimiento obtenido al emplear el subconjunto de características formado por: la magnitud ( $\rho$ ) en coordenada polar y la velocidad ( $v$ ) en coordenadas cartesianas, variando el número de estados ocultos y tamaño del libro de códigos en los modelos utilizados.

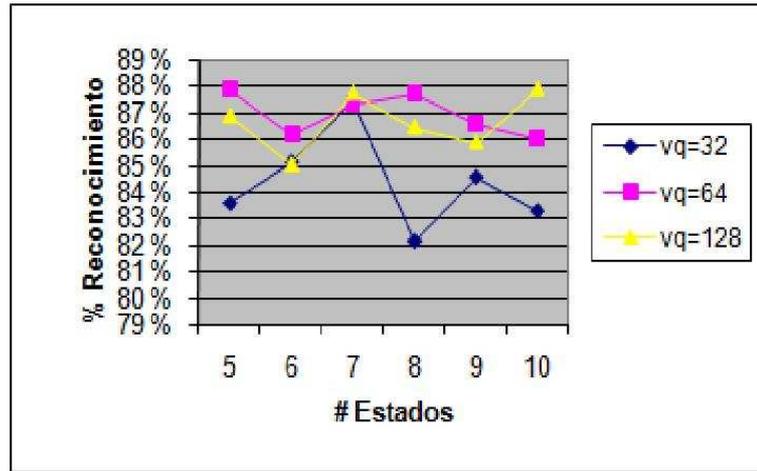


Figura A.13: Reconocimiento al utilizar las características  $\rho\phi\nu$ , variando el número de estados y el tamaño del libro de códigos.

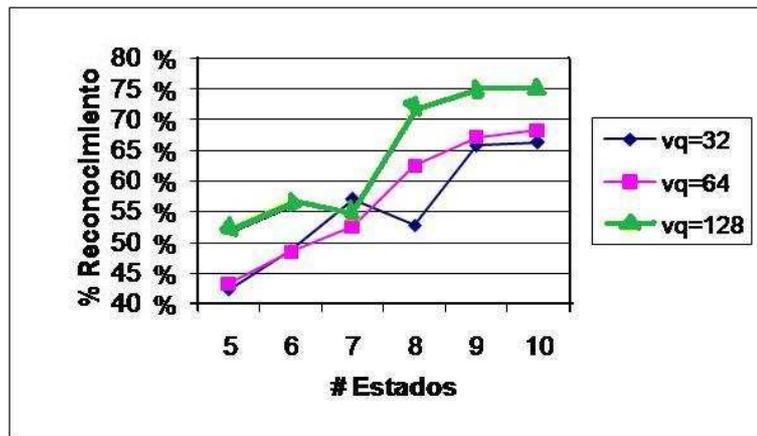


Figura A.14: Porcentaje de reconocimiento promedio alcanzado cuando se utiliza el subconjunto de características: magnitud  $\rho$ , orientación  $\phi$  en coordenadas polares y la posición  $x$  en coordenadas cartesianas. Asimismo, se observa la variación del número de estados ocultos ( $N$ ) y el tamaño del libro de códigos.

En estas pruebas experimentales, el mayor porcentaje de reconocimiento (97%) se obtuvo al utilizar la combinación de características magnitud  $\rho$  y orientación  $\phi$  en coordenadas polares. El número de estados ocultos que manejaron los HMMs donde se alcanzó este porcentaje de reconocimiento fue de 10, y con 64 símbolos de observación. Cuando el subconjunto de características anterior, se combina con la posición ( $x$ ) en coordenadas cartesianas, el porcentaje de reconocimiento baja de 97% a 77% (ver Figura A.14), este mismo caso se repitió con otras combinaciones. Por lo tanto, se determinó a partir de estos análisis, que el subconjunto de características utilizado en este trabajo para representar la trayectoria descrita por el centroide de la mano al describir un gesto manipulativo, sea el formado por: la magnitud ( $\rho$ ) y la orientación ( $\phi$ ) en coordenadas polares.

# Apéndice B

## Especificación de la red de decisión dinámica utilizada

En este anexo se va a mostrar el procedimiento para determinar los parámetros de la red de decisión dinámica (RDD) utilizada en este trabajo. La especificación de parámetros se va a presentar de acuerdo a los escenarios utilizados, por lo tanto iniciamos con el escenario de videoconferencias y posteriormente continuamos con el escenario de apoyo a personas con problemas de memoria (apoyo a discapacitados).

### B.1. Videoconferencia

En esta aplicación se utiliza una RDD la cual representa un caso especial de proceso de decisión de Markov parcialmente observable (POMDP), en el cual la acción seleccionada no afecta el estado del ambiente. En la Figura B.1 se muestran dos etapas de la RDD que se utiliza en este escenario. El conjunto de acciones ( $A$ ) que pueden ser seleccionadas por el sistema son las siguientes.

- $a_1 = \textit{Mostrar – Rostro}$
- $a_2 = \textit{Mostrar – Cuaderno}$
- $a_3 = \textit{Mostrar – Libro}$
- $a_4 = \textit{Mostrar – Pantalla}$

Estas acciones son las que forman los nodos de decisión  $D_1$  y  $D_2$  que aparecen en la Figura B.1. Por otro lado, el conjunto de estados que forman cada nodo aleatorio de la RDD ( $S$ ) son los siguientes.

- $s_1 = \textit{Escribiendo}$
- $s_2 = \textit{Borrando}$
- $s_3 = \textit{Hojeando}$

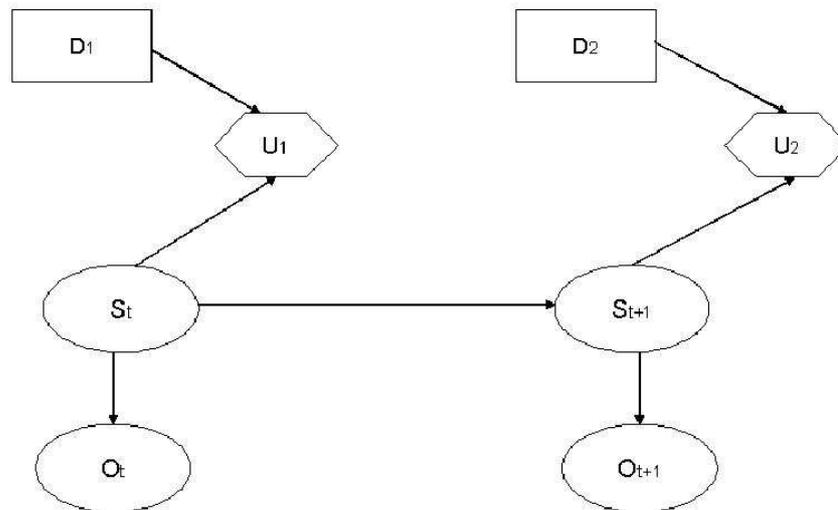


Figura B.1: Red de decisión dinámica utilizada en el escenario de videoconferencia. Se muestran dos etapas temporales y los nodos que forman esta red; nodos de estados ( $S_t, S_{t+1}$ ), nodos de utilidad ( $U_1, U_2$ ), nodos de decisión ( $D_1, D_2$ ) y el nodo de evidencia ( $O_t$ ).

- $s_4 = Usando\ el\ mouse$
- $s_5 = Hablando$

El estado  $s_5$  se considera el estado de *default* cuando el sistema determina que el usuario no está manipulando alguno de los objetos conocidos, es decir cuando no se reconoce ninguno de los gestos representados por el modelo. El nodo de evidencia ( $O$ ) toma la información proveniente de los modelos ocultos de Markov (HMMs). Este nodo proporciona a la RDD la información del gesto más probable que está realizándose en el escenario.

El nodo de utilidad ( $U$ ) representa las preferencias del sistema hacia la selección de acciones. Es decir, proporciona un valor numérico correspondiente a una recompensa o penalización hacia las acciones tomadas por el sistema en relación con sus creencias hacia los estados más probables. Los valores considerados en este trabajo para la recompensa y penalización son respectivamente  $+3$  y  $-3$ . La Figura B.2 muestra la información que contiene este nodo en la RDD utilizada en el escenario de videoconferencia.

Las matrices de transición representan la evolución (dinámica) del sistema en el tiempo. En esta aplicación las matrices de transición mantienen el mismo valor para cada una de las acciones del sistema. Los valores iniciales para esta matriz fueron determinados de manera subjetiva a través de ejemplos. El Procedimiento para obtener estos datos fue el siguiente.

- Se solicitó a 5 personas que expusieran dos veces un tema breve (5 minutos).
- El tema fue el mismo para todas las personas.

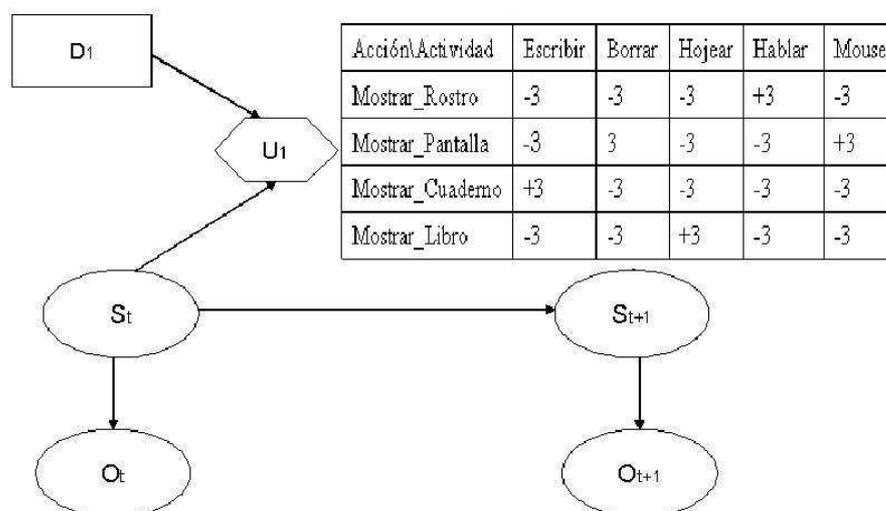


Figura B.2: RDD mostrando los valores correspondientes de la tabla de utilidad. Estos valores numéricos indican las recompensas o penalizaciones del sistema para la selección de acciones. Por claridad en la imagen se omiten los nodos de decisión y de utilidad de la segunda etapa.

- Se les pidió a los participantes que hicieran uso de una hoja para escribir, un libro relacionado con el tema, y de la computadora para apoyar la exposición.
- Se les instruyó a los participantes acerca de que actividades son las que podían realizar.
- El tema fue expuesto por los participantes en dos días consecutivos.

Se anotó de manera cuidadosa el seguimiento de la exposición con el fin de conocer que gesto fue el más frecuente, si en un momento estaban hablando cuál fue la siguiente actividad que más realizaron. A partir de esta información se obtuvo la matriz de transición inicial (Figura B3) que se utilizó para las acciones. La RDD selecciona la acción con la máxima utilidad esperada (MUE) utilizando la siguiente expresión:

$$MUE(S) = \sum_{i=1}^k u_i p(s_i) \quad (B.1)$$

donde  $MUE(S)$  representa la máxima utilidad esperada en el estado ( $S$ ) al momento de seleccionar la acción óptima, considerando el análisis en avance de  $k$  etapas de tiempo a partir de la etapa actual ( $i = 1$ ),  $u_i$  indica la utilidad obtenida en cada etapa analizada,  $p(s_i)$  son las probabilidades de cada estado (gesto) proporcionadas por los HMMs y actualizadas por métodos de inferencia bayesiana.

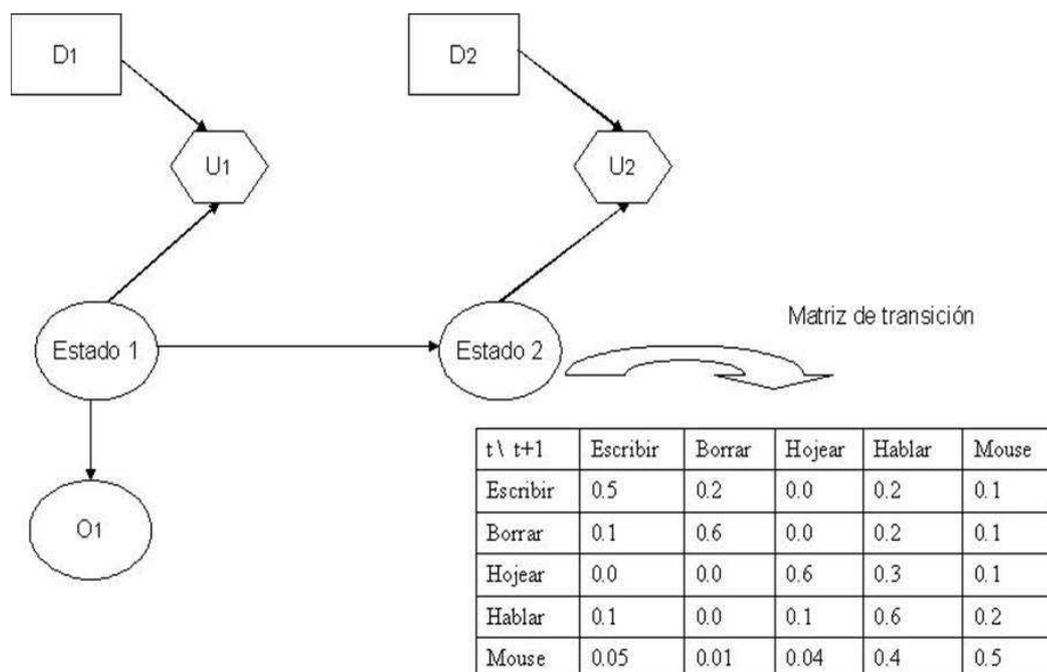


Figura B.3: Matriz de transición utilizada por la RDD aplicada en el escenario de videoconferencia. Esta matriz aparece a partir de la segunda etapa ( $t + 1$ ) tal como se muestra en la figura. El nodo de evidencia ( $O$ ) fue omitido en la segunda etapa para claridad de la imagen.

## B.2. Apoyo a discapacitados

A diferencia del escenario anterior el cual se considera un caso específico de POMDP, en este escenario las acciones tomadas por el sistema si afectan los estados del mismo. En este ambiente, el sistema debe guiar a una persona a través de una secuencia de pasos para que complete una actividad. Para esto, el sistema se va a guiar por un grafo de tareas (ver Figura 6.1), el cual le indica la secuencia correcta de pasos necesarios para que se pueda completar la tarea mencionada. En este caso, el sistema debe considerar si es necesario guiar a la persona (si no sigue la secuencia indicada por el grafo) o solamente observa sin realizar acción alguna (*accion - nula*), si es que sigue la secuencia indicada por el grafo de tareas. Las acciones consisten en mensajes audibles los cuales son seleccionados considerando el gesto más probable (creencias del sistema hacia los estados). Se espera que la acción afecte el comportamiento del usuario, por ejemplo, si se observa que una persona intenta completar la tarea de asearse las manos, y actualmente el sistema determina que está enjabonándose las manos ( $s_t$ ) entonces el sistema espera que la siguiente actividad más probable debe ser lavarse las manos. Si esto ocurre, el sistema selecciona la *accion - nula*, de otra manera selecciona la acción (lávate las manos) que le indique la siguiente actividad que lo conduzca a terminar la tarea. La Figura B.4 muestra tres etapas de la RDD utilizada en esta aplicación. En este escenario el sistema debe evaluar la secuencia de gestos realizados de forma correcta por el usuario para alcanzar su objetivo (completar una tarea). Para esto es necesario que se disponga de una historia de *acciones - observaciones* ocurridas en varias etapas temporales, esto puede convertirse en un problema al manejar escenarios con un número elevado de acciones y/o observaciones. Para simplificar la situación, en nuestro caso no manejamos la historia completa de *acciones - observaciones* ocurridas durante todas las etapas analizadas, sino, solamente consideramos la información de dos etapas como la historia del sistema. Esto puede traer algunos problemas en las acciones seleccionadas, sin embargo intentamos reducirlos proporcionando al nodo de estado actual la información tanto del nodo de decisión anterior ( $D_{t-1}$ ) como del nodo

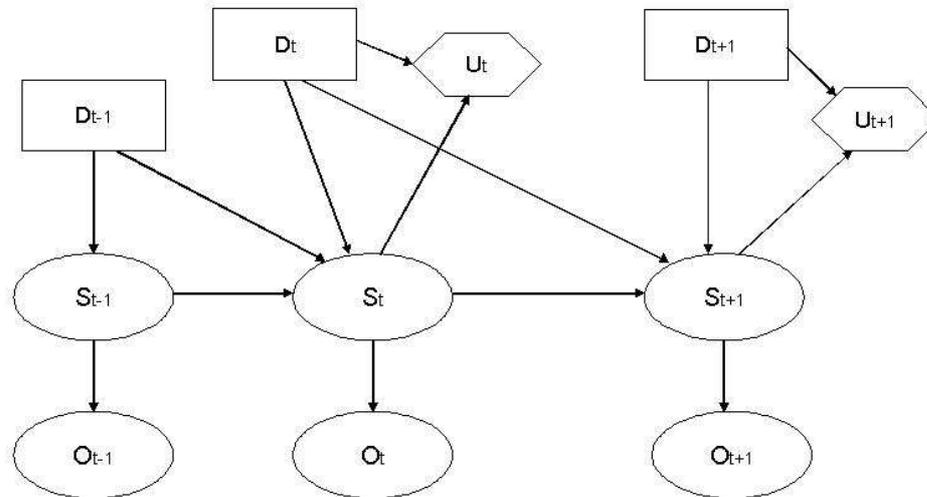


Figura B.4: RDD utilizada en el escenario de apoyo a discapacitados. Se omitió el nodo de utilidad en la etapa de tiempo anterior  $t - 1$  para claridad de la imagen, tampoco se muestran los enlaces de información temporal que conectan a los nodos de decisión. Se observa en cada etapa temporal el efecto de la acción hacia los estados a través del enlace que une los nodos de decisión (rectángulos) y los nodos de estado (óvalos).

actual ( $D_t$ ). Esta información debe modificar el comportamiento de las matrices de transición las cuales determinan en gran medida la evolución temporal del sistema. Las acciones manejadas en este escenario consisten en los siguientes mensajes:

- $a_1$  = Abre el grifo
- $a_2$  = Usa el jabón
- $a_3$  = Enjabónate las manos
- $a_4$  = Lávate las manos
- $a_5$  = Sécate las manos
- $a_6$  = Cierra el grifo
- $a_7$  = Acción nula
- $a_8$  = Solicitar asistencia

Por el momento no se está aplicando la última acción. El sistema se limita a observar el comportamiento de una persona y guiarlo (si es necesario) a realizar los pasos necesarios para terminar una tarea. Los estados que determinan el comportamiento del usuario son en este escenario los siguientes:

Gesto/Acción	Abre el grifo	Usa el jabón	Enjabónate las manos	Lávate las manos	Sécate las manos	Cierra el grifo
Manipulando el grifo	+3	-3	-3	-3	-3	+3
Lavándose las manos	-3	+3	-3	-3	+3	-3
Enjabonándose	-3	-3	-3	+3	-3	-3
Secándose las manos	-3	-3	-3	-3	-3	+3

Figura B.5: Valores numéricos (indicando las preferencias hacia las acciones) que maneja la tabla de utilidades aplicada en el escenario de apoyo a discapacitados.

- $s_1 = \text{Abriendo el grifo}$
- $s_2 = \text{Lavándose las manos}$
- $s_3 = \text{Enjabonándose}$
- $s_4 = \text{Secándose las manos}$
- $s_5 = \text{Cerrando el grifo}$

Consideramos que el gesto *Abriendo el grifo* se refiere a que el usuario está abriendo o cerrando el grifo, para distinguir entre un gesto y otro nos apoyamos en la información de la acción realizada en el tiempo anterior ( $t - 1$ ). Lo mismo sucede con el gesto lavándose las manos, ya que puede ocurrir antes y después de enjabonarse. Al igual que en el escenario anterior, las probabilidades iniciales para las variables aleatorias de los estados son proporcionadas por los HMMs. La acción seleccionada por el sistema se basa en la máxima utilidad esperada y se obtiene aplicando la expresión B.1. Se deben recompensar los pasos realizados de manera correcta y penalizar los que no se realicen correctamente. Para esto, el sistema mantiene en una tabla de utilidades (valores numéricos indicando las preferencias del sistema hacia las acciones). Los valores empleados son los mismos utilizados en el escenario de videoconferencias, es decir, +3 para indicar la preferencia hacia las acciones y -3 en caso contrario. Cuando se considere la acción de solicitar asistencia se le va asignar un valor negativo alto (-6), con la finalidad de que el sistema la utilice como última alternativa. La tabla de utilidades que se utilizó en el segundo escenario se muestra en la Figura B.5.

En este escenario las matrices de transición son diferentes para cada una de las acciones indicando el efecto que cada acción tiene para cada gesto observado. Los valores iniciales para esta matriz fueron determinados de manera subjetiva a través de ejemplos. El Procedimiento para obtener estos datos fue similar al aplicado en el escenario de videoconferencias.

$t \setminus t+1$	Manipulando el grifo	Lavándose las manos	Enjabonándose	Secándose las manos
Manipulando el grifo	0.2	0.7	0.1	0
Lavándose las manos	0.2	0.4	0.2	0.2
Enjabonándose	0	0.57	0.28	0.15
Secándose las manos	0.15	0.28	0	0.71

Acción (t): Lávate las manos

Figura B.6: La tabla muestra los valores de la matriz de transición obtenida al observar el comportamiento de 7 personas cuando el mensaje *lávate las manos* fue proporcionado en el tiempo  $t$ . Este mensaje se proporciona cuando se observa que la persona está abriendo el grifo (*manipulando el grifo*) o está *enjabonándose las manos* (filas primera y tercera). Asimismo, se observa que de los 7 participantes que se estaban enjabonando las manos 5 de ellos pasaron a realizar el gesto esperado (lavándose las manos), 2 continuaron realizando la misma acción, y 1 pasó a realizar una acción diferente al escuchar el mensaje. En esta tabla no se muestra el efecto de la acción realizada en  $t + 1$  la cual tiene como función apoyar el gesto más probable que resulta de la transición.

- Se instruyó a un grupo de 7 participantes para que realizaran la tarea de asearse las manos indicándoles que simularan tener problemas de comprensión o de memoria.
- Una persona se colocó al lado de los participantes para guiarlos a través de instrucciones verbales en la realización de cada gesto.
- Se manejó como límite un tiempo de 3 minutos para completar la actividad.

Se anotó de manera cuidadosa la realización de cada gesto observando la transición y frecuencia entre los gestos, así como el efecto que tuvo cada mensaje en la realización del siguiente gesto. Con esta información se obtuvieron los valores iniciales de las matrices de transición utilizadas en esta RDD. La Figura B.6, muestra los valores de probabilidad de la matriz de transición para la acción *lávate las manos*. Los valores de las probabilidades de transición de las demás matrices de transición presentan resultados similares a la mostrada en la Figura B.6 para el resto de las acciones (mensajes audibles). De esta manera se obtiene la especificación de la RDD utilizada en el escenario apoyo a discapacitados. Posteriormente, los valores de probabilidad son actualizados por información proporcionada por los HMMs y actualizados aplicando métodos de inferencia bayesiana (al igual que el escenario de videoconferencias).