



**I
N
A
O
E**

Aprendizaje Cooperativo de Conceptos para Sistemas Multi-Robot

por

Ana Cristina Palacios García

Tesis sometida como requisito parcial para obtener el grado de
**MAESTRO EN CIENCIAS EN LA ESPECIALIDAD DE
CIENCIAS COMPUTACIONALES** en el Instituto Nacional de
Astrofísica, Óptica y Electrónica

Supervisada por:

Dra. Angélica Muñoz Meléndez
Dr. Eduardo F. Morales Manzanares

Noviembre 2009, Tonantzintla, Puebla

©INAOE 2009

Derechos Reservados

El autor otorga al INAOE el permiso de reproducir y distribuir copias en su totalidad
o en partes de esta tesis



Resumen

En este trabajo de tesis presentamos un método de aprendizaje cooperativo de conceptos para sistemas multi-robot. El aprendizaje cooperativo de conceptos permite aprender conceptos cooperativos a partir de los conceptos individuales aprendidos por los miembros de un sistema multi-robot, es decir, el aprendizaje cooperativo permite que cada miembro del sistema enriquezca su representación individual fusionándola con los conceptos adquiridos por otros robots. Por lo tanto, un robot puede aprender conceptos de objetos no vistos por él mismo en el entrenamiento. En esta tesis, los conceptos son representados a través de características globales PCA (*Principal Component Analysis*) y características locales SIFT (*Scale Invariant Feature Transform*) que son complementarias entre sí. Una vez adquiridos los conceptos individuales, los robots los comparten con los demás miembros del sistema multi-robot para obtener conceptos cooperativos, basándose en el análisis de los conceptos propios y los compartidos por los robots del sistema, es decir, los conceptos cooperativos se obtienen a partir de la detección de información coincidente, complementaria y confusa, y de la fusión de conceptos dependiendo del tipo de información detectada. En la presente tesis, los robots del sistema aprenden en línea empleando aprendizaje no-supervisado tanto conceptos individuales como cooperativos de forma autónoma sin suponer conocimiento *a priori* de cuántos o cuáles objetos van a ser aprendidos por cada robot. Al aprender en línea, el aprendizaje cooperativo de conceptos se distribuye logrando aprender conceptos en menor tiempo que realizando el mismo entrenamiento de forma individual. Las características globales PCA y locales SIFT utilizadas en el esquema propuesto son transformadas a probabilidades mediante funciones de distancia.

Abstract

We present an approach to cooperative learning of concepts in a multi-robot system. Cooperative concepts are generated from individual concepts learned by the robots of the system, i.e., cooperative learning enables members of the multi-robot system to enrich their own concepts merging them with the ones acquired by the other multi-robot members. It means that a robot is able to recognize objects which were not explicitly learned on training, but learned as concepts shared by other robot of the system. The individual concepts are represented using global features PCA (*Principal Component Analysis*) and local features SIFT (*Scale Invariant Feature Transform*) that are complementary. Once the individual concepts have been acquired the robots share them to the other robot members to get cooperative concepts. Cooperative concepts are generated from the analysis of the relationships between individual concepts and individual shared concepts.

In this work the robots of the system autonomously learn individual concepts and cooperative concepts on line using unsupervised learning. Robots did not assume previous knowledge of the learning objects. Cooperative on line concept learning is distributed between robot members to learn concepts in shortest time than time used by applying a individual training.

Global features PCA and local features SIFT used in this work are transformed into probabilities by applying distance functions.

Índice general

Resumen	I
Abstract	III
1. Introducción	1
1.1. Antecedentes	1
1.2. Definición del problema	3
1.3. Objetivos de la tesis	5
1.4. Alcances y limitaciones	5
1.5. Metodología	7
1.6. Organización de la tesis	8
2. Fundamentos	11
2.1. Conceptos básicos	11
2.2. Agente y robot	12
2.3. Sistemas multi-robot	12
2.3.1. Interacción	13
2.3.2. Comunicación	13
2.3.3. Incertidumbre en robótica móvil	14
2.4. Aprendizaje en sistemas multi-robot	15
2.4.1. Aprendizaje individual	17
2.4.2. Aprendizaje concurrente	17

2.5. Reconocimiento de objetos	18
2.5.1. Características Locales	21
2.5.2. Características Globales	24
2.6. Análisis de componentes principales (PCA)	26
2.6.1. Entrenamiento	27
2.6.2. Prueba	27
2.7. Teorema de Bayes	28
2.8. Síntesis	29
3. Estado del Arte	31
3.1. Aprendizaje en Sistemas Mono-Robot	31
3.2. Aprendizaje Cooperativo en Sistemas Multi-Robot	36
3.2.1. Problemas de asignación de créditos y modelado de agentes	37
3.2.2. Dinámica del aprendizaje	39
3.3. Síntesis	43
4. Método propuesto	45
4.1. Descripción general del ambiente	45
4.2. Tipos de objetos	46
4.3. Composición del sistema multi-robot	50
4.4. Esquema general del sistema multi-robot	51
4.5. Entrenamiento individual	52
4.5.1. Detección de objetos	53
4.5.2. Extracción de características y entrenamiento individual	55
4.5.2.1. Entrenamiento PCA	56
4.5.2.2. Entrenamiento SIFT	57
4.6. Comunicación	58
4.7. Aprendizaje cooperativo de conceptos	59
4.7.1. Pre-análisis de conceptos individuales	59
4.7.2. Información coincidente	62

4.7.3.	Información complementaria	65
4.7.4.	Información confusa	67
4.8.	Reconocimiento de objetos	69
4.8.1.	Reconocimiento empleando características PCA	69
4.8.2.	Reconocimiento empleando características SIFT	72
4.8.3.	Reconocimiento empleando la fusión Bayesiana	75
4.9.	Síntesis	77
5.	Experimentos y Resultados	81
5.1.	Criterios de evaluación	82
5.2.	Experimentos de aprendizaje individual de conceptos	82
5.2.1.	Entrenamiento individual	83
5.2.2.	Reconocimiento de objetos	85
5.3.	Experimentos por casos de aprendizaje cooperativo	89
5.3.1.	Experimento con información coincidente	89
5.3.2.	Experimento con información complementaria	96
5.3.3.	Experimentos con información confusa	103
5.3.3.1.	Objetos confusos del tipo 1: diferente forma, características SIFT similares	104
5.3.3.2.	Objetos confusos del tipo 2: forma similar, características SIFT diferentes	109
5.3.4.	Calidad de los conceptos individuales y colectivos	112
5.4.	Experimentos combinados de aprendizaje cooperativo	115
5.4.1.	Experimento combinado de aprendizaje cooperativo de conceptos (fuera de línea)	116
5.4.2.	Experimento combinado de aprendizaje cooperativo de conceptos (en línea)	127
5.5.	Discusión y comparación con otros trabajos	134
5.6.	Síntesis	136

6. Conclusiones y Perspectivas	139
6.1. Síntesis	139
6.2. Aportaciones	140
6.3. Conclusiones y Perspectivas	142
Bibliografía	145
Apéndice A. Ejemplos de conceptos	149

Índice de figuras

2.1. Variaciones que presentan las imágenes durante el reconocimiento visual de objetos.	20
2.2. Diferencia de Gaussianas	23
2.3. Detección de máximos y mínimos locales	24
2.4. Ejemplo de detección de características SIFT en imágenes.	25
2.5. Ejemplos de la silueta y silueta promedio de un objeto.	26
3.1. Histograma de color asociado a una imagen.	32
3.2. Distintos grados de interacción social.	33
3.3. Características de entrenamiento trabajo de ?.	36
3.4. Búsqueda y recolección de objetos.	38
3.5. Combinación de las proyecciones de dos vistas de un objeto.	40
3.6. Segmentación de la imagen usando filtros Kalman.	41
3.7. Técnica de Forma de la Silueta (SFS).	42
4.1. Ambiente del sistema multi-robot.	46
4.2. Ejemplo de un objeto simétrico verticalmente.	47
4.3. Ejemplo de un objeto no simétrico verticalmente.	48
4.4. Tipos de objetos detectados por sus características locales.	49
4.5. Los dos robots miembros del sistema multi-robot.	50
4.6. Esquema general del sistema multi-robot.	53
4.7. Concepto individual SIFT de un objeto dado.	57

4.8. Trayectorias que permiten la obtención de información coincidente.	63
4.9. Trayectorias que permiten la obtención de información complementaria.	66
5.1. Experimento individual: Objetos de entrenamiento	83
5.2. Experimento individual: Proyecciones de las siluetas de los objetos de entrenamiento	84
5.3. Experimento individual: Características SIFT de los objetos de entrena- miento.	85
5.4. Experimento individual: Gráficas de reconocimiento individual.	87
5.5. Objetos de entrenamiento del experimento con información coincidente.	90
5.6. Probabilidades de clasificación PCA - experimento con información coin- cidente.	93
5.7. Probabilidades de clasificación SIFT - experimento con información coin- cidente.	93
5.8. Probabilidades de clasificación Bayesianas - experimento con informa- ción coincidente.	94
5.9. Objetos de entrenamiento R1: experimento con información complemen- taria.	96
5.10. Objetos de entrenamiento R2: experimento con información complemen- taria.	96
5.11. Probabilidades de clasificación PCA: experimento con información com- plementaria.	101
5.12. Probabilidades de clasificación SIFT: experimento con información com- plementaria.	101
5.13. Probabilidades de clasificación Bayesiana: experimento con información complementaria.	102
5.14. Objetos de entrenamiento aprendidos por el robot R1, experimento con información confusa del tipo 1.	105

5.15. Objetos de entrenamiento aprendidos por el robot R2, experimento que contiene información confusa del tipo 1.	105
5.16. Probabilidades de clasificación PCA: experimento con información confusa tipo 1.	106
5.17. Probabilidades de clasificación SIFT: experimento con información confusa tipo 1.	107
5.18. Probabilidades de clasificación Bayesiana: experimento con información confusa tipo 1.	107
5.19. Objetos de entrenamiento aprendidos del experimento con información confusa tipo 2.	110
5.20. Imagen eslabón <i>hip-ot</i>	110
5.21. Porcentajes promedio de cobertura empleando la parte PCA de los conceptos.	113
5.22. Porcentajes promedio de cobertura empleando la parte SIFT de los conceptos.	113
5.23. Porcentajes promedio de cobertura empleando la fusión Bayesiana.	114
5.24. Objetos de entrenamiento experimento general de aprendizaje cooperativo fuera de línea.	117
5.25. Trayectorias de entrenamiento experimento general de aprendizaje cooperativo (fuera de línea).	118
5.26. Trayectorias de los robots en el experimento general de aprendizaje cooperativo para el reconocimiento de objetos.	122
5.27. Probabilidades de clasificación PCA: experimento de aprendizaje cooperativo fuera de línea.	123
5.28. Probabilidades de clasificación SIFT: experimento de aprendizaje cooperativo fuera de línea.	124
5.29. Probabilidades de clasificación Bayesiana: experimento de aprendizaje cooperativo fuera de línea.	124
5.30. Trayectorias de entrenamiento para el experimento general en línea.	128

5.31. Probabilidades de clasificación PCA: experimento de aprendizaje cooperativo en línea.	132
5.32. Probabilidades de clasificación SIFT: experimento de aprendizaje cooperativo en línea.	133
5.33. Probabilidades de clasificación Bayesiana: experimento de aprendizaje cooperativo en línea.	133
5.34. Comparación con trabajos relacionados.	137

Índice de tablas

5.1. Porcentajes de clasificación obtenidos en el experimento individual.	88
5.2. Porcentajes de clasificación promedio de seis experimentos individuales. . .	88
5.3. Vectores de probabilidades PCA y SIFT: experimento con información coincidente del robot R1.	91
5.4. Vectores de probabilidades PCA y SIFT del experimento con información coincidente del robot R2.	91
5.5. Porcentajes de clasificación - información coincidente.	94
5.6. Vectores de probabilidades PCA del robot R1: experimento con informa- ción complementaria.	98
5.7. Vectores de probabilidades SIFT del robot R1: experimento con informa- ción complementaria.	98
5.8. Tipos de información detectada por el robot R1: experimento con infor- mación complementaria.	99
5.9. Vectores de probabilidades PCA del robot R2: experimento con informa- ción complementaria.	99
5.10. Vectores de probabilidades SIFT del robot R2: experimento con informa- ción complementaria.	100
5.11. Porcentajes de clasificación de información complementaria.	102
5.12. Vectores de probabilidades PCA y SIFT del robot R1: experimento con información confusa.	106
5.13. Porcentajes de clasificación de información confusa tipo 1.	108

5.14. Vectores de probabilidades PCA y SIFT: experimento con información confusa del tipo 2.	111
5.15. Vectores de probabilidades PCA del robot R1: experimento general (fuera de línea).	117
5.16. Vectores de probabilidades SIFT del robot R1: experimento general (fuera de línea).	119
5.17. Vectores de probabilidades PCA del robot R2: experimento general (fuera de línea).	119
5.18. Vectores de probabilidades SIFT del robot R2: experimento general (fuera de línea).	120
5.19. Tipos de información detectada por el robot R1: experimento aprendizaje cooperativo fuera de línea.	121
5.20. Tipos de información detectada por el robot R2: experimento de aprendizaje cooperativo fuera de línea.	121
5.21. Porcentajes de clasificación: experimento de aprendizaje cooperativo fuera de línea.	125
5.22. Vectores de probabilidades PCA del robot R1: experimento general (en línea).	129
5.23. Vectores de probabilidades SIFT del robot R1: experimento general (en línea).	130
5.24. Vectores de probabilidades PCA del robot R2: experimento general (en línea).	130
5.25. Vectores de probabilidades SIFT del robot R2: experimento general (en línea).	131
5.26. Tipos de información detectada por el robot R1: experimento aprendizaje cooperativo en línea.	131
5.27. Tipos de información detectada por el robot R2: experimento de aprendizaje cooperativo en línea.	132

5.28. Porcentajes de clasificación: experimento de aprendizaje cooperativo en línea.	134
5.29. Criterios considerados en la comparación propuesta.	138

Capítulo 1

Introducción

1.1. Antecedentes

El diseño de sistemas multi-robot se ha convertido en un área de investigación de gran relevancia en la comunidad de robótica móvil. Esto se debe a que los sistemas multi-robot surgen como una alternativa al diseño y control de sistemas robóticos, debido principalmente a sus capacidades para explotar la redundancia tanto en la percepción como en la actuación de los robots.

Por lo regular, los trabajos reportados empleando sistemas multi-robot se enfocan en el desarrollo de mecanismos que permitan a los robots autónomos realizar tareas colectivas, algunos ejemplos son: estrategias de coordinación y comunicación (Asada et al. (1994); Matarić (1997)), localización de recursos (Fernández et al. (2005)), y toma de decisiones descentralizadas (Murphey y Pardalos (2002)). En estos trabajos, el sistema multi-robot ofrece ventajas principalmente en términos del tiempo necesario para completar una tarea asignada al sistema completo.

A pesar de la constante investigación en el diseño de sistemas multi-robot, se ha puesto poca atención al desarrollo de sistemas capaces de aprender a partir de su interacción con el ambiente. Un sistema multi-robot capaz de aprender, puede adquirir información más rica y variada comparada con la información adquirida por un solo robot aprendiz.

Generalmente se espera que el proceso de aprendizaje no sea centralizado, pues se corre el riesgo de que el robot que realiza el aprendizaje pueda “colapsar” perdiéndose con él toda la información adquirida.

El aprendizaje es indispensable tanto para un robot como para un sistema multi-robot para alcanzar su autonomía. En el contexto de sistemas multi-robot, el aprendizaje por refuerzo ha sido constantemente aplicado para mejorar la coordinación de acciones individuales que permitan lograr objetivos comunes (Asada et al. (1994); Matarić (1997); Yang y Gu (2004); Fernández et al. (2005); Corchado et al. (2008)).

En este trabajo se aborda el aprendizaje cooperativo realizado por un sistema multi-robot para aprender objetos usando únicamente información visual de los mismos. El hecho de usar información visual de los objetos, es decir, imágenes de ellos, es una fuente de percepción primaria que proporciona características locales y globales útiles para realizar el aprendizaje de los objetos. Sin embargo, éstas características de forma independiente no brindan suficiente información para realizar una discriminación aceptable entre los distintos objetos. En este trabajo suponemos que las características locales y las globales son complementarias entre sí, pues proporcionan diferentes tipos de información.

En este trabajo, los robots aprenden conceptos de las imágenes de los objetos. Los conceptos se forman por las características locales SIFT (*Scale Invariant Features*, Lowe (2004)) y por los PC (*Principal Components*) de las siluetas de los objetos. Para el reconocimiento de objetos los robots realizan una fusión Bayesiana que combina ambas características.

Existen diversas dificultades en los sistemas multi-robot que surgen durante el aprendizaje y la compartición de conceptos que representan a objetos concretos. Algunas de estas dificultades son discutidas por Ye and Tsotsos (Ye y Tsotsos (1996)) e incluyen, ¿cómo los robots representan sus vistas locales del mundo?, ¿cómo se actualiza el conocimiento local como consecuencia de las propias acciones del robot?, ¿cómo los robots representan las vistas locales de otros robots?, ¿cómo organizan el conocimiento propio y el de los demás robots de tal forma que nuevos hechos puedan integrarse fácilmente a la representación?. En este trabajo abordamos aquellos aspectos que tienen que ver con la

representación individual y colectiva de objetos a partir de la información visual adquirida por un sistema multi-robot consistente de dos robots.

Un sistema multi-robot capaz de aprender autónomamente objetos usando únicamente información visual de ellos tiene distintas aplicaciones, por ejemplo, en problemas de localización local y global, y en tareas de servicio como buscar objetos en ambientes desconocidos.

1.2. Definición del problema

En este trabajo se propone abordar el problema del análisis y fusión de los conceptos aprendidos y compartidos por cada robot del sistema multi-robot. Lo anterior permitirá adquirir conceptos colectivos a partir de la detección de información coincidente, complementaria y confusa entre los conceptos propios y compartidos por los robots del sistema.

Algunos subproblemas a considerar son: (i) La representación que los robots deben tener de los objetos, es decir, los conceptos aprendidos por cada robot de cada objeto de entrenamiento, pues deben ser lo suficientemente robustos para considerar y distinguir casos en los que objetos distintos pueden poseer texturas lisas o semi-lisas, o texturas similares a las de otro objeto, o tener la misma forma siendo diferentes objetos, entre otras. Por lo regular, la representación de objetos en sistemas mono-robot y multi-robot se realiza tomando en cuenta o bien características locales o globales de los objetos. Además, hasta donde sabemos, en trabajos relacionados se considera que todos los objetos de entrenamiento son distintos, sin importar coincidencias en la forma o en la textura de los objetos que pueden indicar que se trata de un mismo objeto, con lo cual es posible evitar sobre-representar al objeto en más de un concepto (Steels y Kaplan (2001); O'Beirne y Schukat (2004); Ekvall et al. (2006)). (ii) Los robots deben aprender individualmente conceptos sin tener una guía predefinida, es decir, sin tener conocimiento *a priori* de la cantidad y el tipo de objetos a aprender durante el entrenamiento. (iii) Para alcanzar la cooperatividad entre los robots del sistema, éstos necesitan determinar qué compartir y

cómo fusionar sus conceptos. En este punto es importante el cómo los robots del sistema multi-robot determinan que se trata de un mismo objeto o de uno nuevo, a partir de los conceptos adquiridos por los robots individualmente de los distintos objetos de entrenamiento observados por cada uno.

Esta propuesta de tesis tiene como propósito la formación de conceptos colectivos considerando la información adquirida individualmente y la compartida por los miembros de un sistema multi-robot.

El enfoque propuesto consiste de tres etapas, el entrenamiento individual, la compartición de conceptos, y el análisis y fusión de conceptos. En el entrenamiento individual cada miembro del sistema multi-robot aprende un concepto por cada objeto visto, de tal forma que los conceptos representan a los objetos de entrenamiento. En este caso, un concepto consta de dos partes, la parte que describe la forma del objeto y la parte que describe las características locales del objeto. Al conjunto de conceptos aprendidos individualmente por cada robot del sistema multi-robot le llamaremos conceptos individuales.

La compartición de conceptos individuales entre los robots del sistema multi-robot se realiza a través de una red inalámbrica *WiFi*.

El análisis y fusión de conceptos permite identificar tres tipos de información inmersa entre los conceptos, es decir, información coincidente, complementaria y confusa ¹. Dependiendo del tipo de información detectada durante el análisis será el tipo de fusión de datos a realizar, lo que permite el aprendizaje cooperativo de conceptos. Al conjunto de conceptos resultantes del análisis y fusión de conceptos les llamaremos conceptos colectivos, pues se adquieren empleando la información de los miembros del sistema multi-robot.

El método propuesto toma en cuenta dos casos, aprendizaje cooperativo de conceptos fuera de línea y el aprendizaje cooperativo de conceptos en línea. La principal diferencia entre el aprendizaje cooperativo de conceptos fuera de línea y el realizado en línea, es que en el primero la compartición de conceptos se realiza una vez aprendidos todos los objetos de entrenamiento, mientras que en el aprendizaje cooperativo de conceptos en

¹Más adelante en la tesis se da una definición precisa de estos conceptos (cf. sección 4.7).

línea, la compartición se realiza cada vez que un objeto es aprendido por los robots.

1.3. Objetivos de la tesis

El objetivo general de la tesis es desarrollar un método de aprendizaje cooperativo de conceptos para sistemas multi-robot.

Para alcanzar el objetivo propuesto se han identificado los siguientes objetivos particulares:

- Proponer e implementar esquemas de representación que definan a un conjunto de objetos físicos a partir de la información visual adquirida por los robots.
- Aprender conceptos individuales de los objetos vistos por los robots, a partir de ejemplos o imágenes capturadas de ellos usando el esquema de representación del objetivo anterior.
- Realizar el análisis y la fusión de las representaciones o conceptos individuales propios y compartidos entre los miembros del sistema multi-robot.
- Aplicar los conceptos individuales y cooperativos en una tarea de reconocimiento de objetos usando robots reales.

1.4. Alcances y limitaciones

Los alcances y limitaciones de la presente tesis son los siguientes:

- Durante el entrenamiento individual los robots del sistema desconocen la cantidad de objetos a aprender. Esto plantea muchos problemas en cuanto a que los robots deben determinar si un concepto individual corresponde a un objeto previamente aprendido o no.

- Los conceptos individuales se aprenden tanto en línea como fuera de línea mientras que los robots van recorriendo un ambiente particular. Esto es importante para alcanzar la autonomía del sistema.
- Se identifican tres casos posibles de información inmersa entre los conceptos propios y los compartidos. Además, se muestra el cómo fusionarlos.
- En esta tesis se obtienen conceptos colectivos a partir de conceptos individuales adquiridos por los miembros del sistema multi-robot. Los conceptos colectivos permiten que cada robot tenga una representación más completa de los objetos de entrenamiento respecto a los conceptos individuales aprendidos por él mismo.
- Los robots emplean los conceptos colectivos en una tarea de reconocimiento de objetos, de tal forma que los robots podrán reconocer además de los objetos con los cuales fueron entrenados, a aquellos objetos aprendidos por algún otro robot del sistema.
- En esta tesis se supone que los objetos a aprender pueden segmentarse del fondo del ambiente. Por esta razón se utiliza un ambiente con fondo uniforme.
- El ambiente se encuentra distribuido de tal forma que un robot no pueda capturar con su cámara de video a dos o más objetos de forma simultánea.
- La variedad de objetos que pueden ser reconocidos visualmente con una cámara CCD es muy amplia, es por eso que se aplicaron técnicas de reconocimiento de objetos que cubren una amplia gama: objetos que se reconocen por características generales como histograma de color, textura, forma, etc., y objetos que se reconocen por sus características locales, como puntos característicos en áreas localizadas de una imagen.
- El trabajo propuesto está orientado al aprendizaje de conceptos empleando más de un robot. En esta tesis, principalmente por limitaciones de equipo, nos limitamos a dos robots.

1.5. Metodología

Se aplicó la siguiente metodología para alcanzar los objetivos enunciados anteriormente.

1. **Entrenamiento individual.** En esta fase cada robot obtiene imágenes de los distintos objetos de entrenamiento a lo largo de una trayectoria predefinida, y extrae un concepto individual del conjunto de imágenes correspondientes a un mismo objeto, el cual consiste de una silueta y de un conjunto de características locales que representan al objeto.
2. **Compartición de las representaciones.** En este punto se intercambian los conceptos individuales adquiridos por cada miembro del sistema multi-robot a través de una red inalámbrica *WiFi*.
3. **Análisis y fusión de los conceptos individuales propios y compartidos por los robots miembros del sistema multi-robot.** Este análisis se debe realizar de acuerdo a los siguientes tipos de información que pueden presentarse entre los conceptos individuales propios y compartidos, en donde el tipo de información determinará el tipo de fusión de datos a realizar:
 - a) **Información coincidente.** Pueden encontrarse coincidencias entre los conceptos individuales las cuales permiten reafirmar lo aprendido por los robots.
 - b) **Información complementaria.** En este punto pueden detectarse conceptos individuales adquiridos por algún robot particular del sistema, que no se encuentran en el robot actual, en este caso se agrega lo nuevo ya que no contradice lo conocido.
 - c) **Información confusa.** Puede detectarse la existencia de información confusa entre los conceptos individuales propios y compartidos. La confusión puede surgir por la forma de los objetos o por sus características locales, y concierne aquellos casos en que un objeto es tomado por otro. En la presente tesis se

detectan confusiones específicas y debido a que esta información es indistinguible de la información complementaria, los conceptos se tratan igual, con el riesgo de “sobrerepresentar” un objeto en más de un concepto.

Un caso difícil de tratar que se presenta como información confusa se origina cuando los robots aprenden vistas completamente distintas de un mismo objeto. En esta situación se exploran soluciones alternativas que se basan en la búsqueda de “intersecciones” en los conceptos aprendidos por cada robot para tratar de “deducir” que se trata del mismo objeto, consiguiendo enriquecer la representación de un mismo objeto sin sobrerepresentarlo.

4. **Aplicación del conocimiento que resulte.** En este punto se aplican tanto los conceptos individuales como los cooperativos en una tarea de reconocimiento de objetos, con lo cual se comprueba experimentalmente la robustez de los conceptos cooperativos respecto a los conceptos adquiridos individualmente. Además, los conceptos cooperativos también son más “completos” que los conceptos individuales pues contienen conceptos de objetos con los cuales el robot actual no fue entrenado directamente, así como conceptos “enriquecidos” con información proporcionada por otro robot.
5. **Evaluación.** Para evaluar el desempeño del método propuesto, se midió el porcentaje de clasificación en función del número de imágenes en las que fue correctamente detectado un objeto entre el total de imágenes de prueba para el objeto dado.

1.6. Organización de la tesis

La tesis se encuentra organizada en seis capítulos. En el capítulo 2 se presentan los fundamentos teóricos de lo que es un sistema multi-robot así como los tipos de comunicación e interacción entre los miembros de estos sistemas. También se describen algunos de los problemas al emplear robots móviles. En este capítulo se presenta además lo que es el reconocimiento de objetos seguido por los tipos de características actualmente usa-

das. Posteriormente, se menciona la regla de Bayes empleada para el reconocimiento de objetos en la presente tesis. En el capítulo 3 se realiza el estudio del estado del arte para el aprendizaje cooperativo en sistemas multi-robot. También se describe brevemente el aprendizaje mono-robot, y algunos de los trabajos relacionados con el contenido de la presente tesis. En el capítulo 4 se presenta el enfoque de aprendizaje cooperativo de conceptos para sistemas multi-robot propuesto en esta tesis. En este capítulo se describe el proceso del entrenamiento individual seguido por cada robot del sistema, la comunicación entre los robots, el análisis y fusión de conceptos, y finalmente, el proceso de reconocimiento de objetos. En el capítulo 5 se dan a conocer los experimentos, la evaluación realizada a los conceptos adquiridos por los robots, y una comparación con trabajos relacionados. Finalmente, en el capítulo 6 se dan a conocer las conclusiones y se plantean las perspectivas de esta tesis.

Capítulo 2

Fundamentos

En este capítulo se revisarán algunos de los conceptos relacionados con el contenido de la tesis.

2.1. Conceptos básicos

Definición 1. *Un concepto es una representación de características distintivas un objeto visto por un robot. En nuestro caso, un concepto se forma por dos partes, la parte que describe las características locales del objeto y la parte que describe la forma del objeto.*

Definición 2. *El aprendizaje de conceptos es un método de adquisición de conceptos que describen a los distintos objetos de entrenamiento empleando técnicas de extracción de características.*

Cabe señalar que el aprendizaje de conceptos en la literatura de aprendizaje computacional, permite inferir automáticamente las definiciones generales de algunos conceptos, dados ejemplos etiquetados de miembros y no miembros del concepto (Mitchell (1997)).

Definición 3. *Por **concepto colectivo** nos referimos a los conceptos aprendidos por los robots después de realizar un análisis y fusión sobre los conceptos propios y compartidos entre los robots del sistema. Los conceptos colectivos conservan las dos partes que forman a un concepto, es decir, la parte que describe las características locales de un objeto y la parte que describe la forma del objeto.*

Definición 4. *Un **comportamiento** se refiere a la reacción del robot ante un estímulo dado (Floreano y Mattiussi (2008)). Algunos ejemplos de comportamientos básicos aprendidos por un robot móvil son: evadir obstáculos, moverse en una dirección, girar hacia algún lado, entre otros.*

2.2. Agente y robot

Definición 5. *Un **agente** es un sistema de computo que tiene capacidad de percepción, toma de decisiones y ejecución de acciones por sus propios medios.*

Un agente puede percibir su entorno a través de sus sensores y actuar en el entorno usando sus activadores. Dependiendo del tipo de entorno en que esta inmerso el agente puede tomar diferentes formas. Por ejemplo, un agente inmerso en el mundo físico es típicamente conocido como un **robot** (Liu y Wu (2001)).

2.3. Sistemas multi-robot

Definición 6. *Un **sistema multi-robot** es aquel compuesto por dos o más robots diseñados para realizar tareas conjuntas y alcanzar objetivos comunes*

(Jiménez-Velasco (2006)).

Para que los miembros de un sistema multi-robot sean capaces de realizar tareas conjuntas y de alcanzar objetivos comunes son necesarias la **interacción** y la **comunicación** entre los robots del sistema. Además, también deberá considerarse la **incertidumbre** existente en robótica móvil, ya que esta última origina la mayor parte de problemas en robótica en ambientes reales.

2.3.1. Interacción

La interacción entre los robots del sistema multi-robot se refiere a la relación existente entre los robots del sistema, y entre éstos y su medio ambiente. Son las interacciones existentes entre los robots las que hacen que las acciones ejecutadas por algunos de los robots tengan influencia en otros robots del sistema. La interacción dentro del sistema multi-robot es indispensable para alcanzar objetivos comunes.

En este trabajo los robots interactúan entre sí al compartir sus conceptos individuales con la finalidad de formar conceptos cooperativos.

2.3.2. Comunicación

Definición 7. *La comunicación en un sistema multi-robot es la capacidad que poseen los miembros del sistema para transmitir y recibir información entre ellos. La información es codificada empleando un lenguaje que es conocido por todos los miembros del sistema multi-robot (Jiménez-Velasco (2006)).*

La comunicación puede realizarse de forma directa a través de un canal de comunicación explícito, o de forma indirecta en que un robot percibe cambios en otros robots que se encuentran en su ambiente (Balch y Parker (2002)). Michaud y Vu (1999) presentan

un ejemplo de robots que se comunican indirectamente a través de luces externas, lo cual permite a los robots comunicar motivaciones, i.e., dependiendo de la secuencia en las luces emitidas por un robot, se le indica a otro u otros robots información para tomar ciertas acciones o adquirir información del ambiente cuando se les es sugerido. Este mismo esquema ha sido aplicado por Jiménez-Velasco (2006) para la comunicación de los módulos del sistema multi-robot modular Mini-trans.

En el presente trabajo los robots se comunican de forma directa a través de una red inalámbrica *WiFi*.

2.3.3. Incertidumbre en robótica móvil

Según Thrun et al. (2005) hay cinco factores principales que contribuyen en la incertidumbre de la adquisición de datos y ejecución de acciones en los robots móviles. Estos factores se describen a continuación:

1. **El ambiente del robot:** Los robots industriales por lo regular operan en ambientes estructurados y controlados. Sin embargo, los robots que ejecutan tareas en otros ambientes (no estructurados o semi-estructurados), tienen que tomar en cuenta que los modelos que se tienen de dichos ambientes pueden variar, por ejemplo, por la presencia de personas.
2. **Los sensores.** Los sensores son dispositivos electrónicos, y por lo tanto están sujetos a ciertas limitaciones físicas. Además, dependiendo de su tipo, los sensores presentan ruido que es difícil de modelar y que provoca que la información que se obtenga de ellos sea limitada e imprecisa.
3. **La actuación del robot.** El robot ejecuta acciones en su ambiente mediante efectores o activadores, los cuales tampoco están exentos de incertidumbre, i.e. las acciones no se ejecutan tal y como se programaron. La incertidumbre en los efectores puede deberse a ruido en el control, a fallas mecánicas o eléctricas, o a factores externos del ambiente.

4. **Modelos internos.** Los modelos son abstracciones del mundo real y por lo tanto son sólo aproximaciones de éste.
5. **Algoritmos aproximados.** Los robots son sistemas que suelen operar en tiempo real, en cuyo caso, sus cálculos deben realizarse en el menor tiempo posible. Lo anterior provoca que muchos algoritmos sean simplificados sacrificando precisión.

Además, hay que considerar que la incertidumbre se incrementa cuando se tiene un sistema multi-robot en lugar de un solo robot. En este trabajo algunos de los factores que contribuyen en la incertidumbre son principalmente: cambios en la intensidad de iluminación, errores en la segmentación de los objetos, errores en el sensor (cámara de video), entre otros.

2.4. Aprendizaje en sistemas multi-robot

Definición 8. *El aprendizaje en sistemas multi-robot o aprendizaje cooperativo en sistemas multi-robot se refiere a la aplicación de aprendizaje computacional a problemas que involucran múltiples robots (Panait y Luke (2005)).*

El aprendizaje en sistemas multi-robot es particularmente complejo debido a diversas situaciones: (i) pueden tenerse espacios de estados grandes. Por ejemplo, para la tarea de forrajeo (*foraging*) cuyo objetivo es que los robots recorran un ambiente buscando y recolectando objetos para su posterior colocación en un lugar del ambiente conocido como *home*, el robot “aprendiz” puede encontrarse en alguno de los estados: en *home*-sin objeto, frente a un objeto, sosteniendo un objeto, en *home*-sosteniendo un objeto, entre otros, y lo mismo ocurre con los demás robots del sistema. Por lo tanto, el robot “aprendiz” debe considerar su estado y el estado en el que pueden encontrarse todos los robots del sistema en cada estado posible. (ii) Incertidumbre en la asignación de créditos. Esta situación ocurre al emplear aprendizaje por refuerzo, pues es necesario determinar el cómo asignar créditos o recompensas a las acciones que se desea aprender, y al mismo tiempo penalizar

aquellas que no. (iii) Tiempo de entrenamiento limitado. Esto ocurre principalmente a que los robots poseen fuentes de energía limitadas, por lo cual es preferible que el tiempo de entrenamiento sea el menor posible. (iv) Incertidumbre en la percepción y al compartir información, (v) dificultad al definir representaciones adecuadas de la información aprendida por cada robot (Ye y Tsotsos (1996)), (vi) problemas al combinar la información aprendida por diferentes robots (Ye y Tsotsos (1996)). En este trabajo abordamos los problemas (iv) y (v), es decir, el de cómo representar a los objetos observados por cada robot, y el del cómo combinar los conceptos aprendidos por los distintos robots del sistema.

Existen tres tipos de aprendizaje: **supervisado**, **no-supervisado** y el **aprendizaje por refuerzo**. Estos tipos de aprendizaje se diferencian entre sí por la clase de retro-alimentación que recibe el aprendiz del experto. En el aprendizaje supervisado el experto proporciona la salida correcta. En el aprendizaje no-supervisado no existe ningún tipo de retro-alimentación. En el aprendizaje por refuerzo el experto define una recompensa de acuerdo al resultado obtenido por el aprendiz. En todos los casos el aprendiz puede ser una entidad de software o hardware, y el experto puede ser un usuario con conocimiento general del problema.

En general, el aprendizaje supervisado no puede ser aplicado directamente a problemas en los que surge cierta complejidad en las interacciones entre los componentes de los sistemas multi-robot, debido a que en este tipo de aprendizaje se presupone que un experto puede indicar el comportamiento correcto para una situación dada en cualquier momento. Es por esto que la mayor parte de los trabajos realizados en el área de aprendizaje para sistemas multi-robot han empleado diferentes variantes del aprendizaje por refuerzo y en menor medida aprendizaje no-supervisado para adaptarlos a un contexto cooperativo, con lo cual los robots aprenden generalmente comportamientos “cooperativos”. En el presente trabajo cada robot del sistema emplea aprendizaje no-supervisado para aprender conceptos de los distintos objetos de entrenamiento, pues los robots no suponen conocimiento *a priori* de el número o tipo de objetos a aprender.

Según Panait y Luke (2005) existen dos categorías principales del aprendizaje cooperativo en sistemas multi-robot: aprendizaje individual (*team learning*) y aprendizaje con-

corriente (*concurrent learning*), las cuáles se describen a continuación.

2.4.1. Aprendizaje individual

En el aprendizaje individual es un solo robot el que aprende descubriendo un conjunto de comportamientos para el grupo de robots completo. Este tipo de aprendizaje es el más simple debido a que el robot que aprende puede emplear distintas técnicas de aprendizaje computacional estándares¹. Además, los comportamientos adquiridos por el robot “aprendiz” están estrechamente ligados a mejorar el desempeño del sistema completo. Por lo regular los autores que emplean este tipo de aprendizaje utilizan técnicas de aprendizaje por refuerzo.

Algunos de los inconvenientes de este tipo de aprendizaje cooperativo en el que se emplean refuerzos son: (i) Pueden haber espacios de estados muy grandes durante el proceso de aprendizaje. (ii) Dependiendo de la cantidad de robots del sistema multi-robot, se incrementa el espacio de estados, ya que el robot “aprendiz” toma en cuenta, a partir de cada uno de los estados en los que puede encontrarse, el número de estados en que puede encontrarse cada robot, para ser capaz de aprender cómo actuar frente a cualquier situación dada.

Por otro lado, el uso de un algoritmo de aprendizaje centralizado implica que todos los recursos necesarios para el aprendizaje deban estar disponibles en el lugar y el momento donde se realiza el aprendizaje.

2.4.2. Aprendizaje concurrente

En el aprendizaje concurrente, generalmente cada robot tiene su propio proceso de aprendizaje que le permite adaptar sus comportamientos en el contexto de múltiples robots “co-adaptándose” entre sí con otros robots sobre los cuales no tienen control alguno.

Uno de los problemas de este tipo de aprendizaje cooperativo es que conforme los

¹Por técnicas de aprendizaje computacional estándares nos referimos a aquellas técnicas más usadas en robótica, por ejemplo, aprendizaje por refuerzo y aprendizaje basado en instancias.

robots aprenden van modificando sus comportamientos, lo cual puede llevar a que se afecten los comportamientos ya aprendidos por otros robots haciéndolos posiblemente obsoletos. Un método simple para lidiar con los problemas de co-adaptación es tratar a los otros robots como parte de un entorno dinámico al cual cada robot aprendiz debe adaptarse. Por lo regular los autores que emplean este tipo de aprendizaje concurrente desarrollan técnicas en las que involucran aprendizaje por refuerzo para considerar la colaboración entre los robots con los distintos refuerzos empleados.

Debido a que cada robot es libre de aprender de forma independiente, no resulta útil hacer una distinción entre los aspectos de homogeneidad y heterogeneidad entre los miembros del sistema multi-robot. Sin embargo, hay otros aspectos de éstos sistemas que son interesantes de abordar, como son las tres áreas de investigación que se desprenden del aprendizaje concurrente:

1. **Problemas de asignación de créditos:** Tiene que ver con el cómo proporcionar las recompensas obtenidas a nivel de sistema multi-robot a los robots individuales.
2. **Dinámica del aprendizaje:** Se trata de entender el impacto de la co-adaptación entre los miembros del sistema multi-robot en el proceso de aprendizaje.
3. **Modelado de otros agentes:** Los trabajos realizados en ésta área de investigación se han realizado para mejorar las interacciones y la colaboración entre los robots.

2.5. Reconocimiento de objetos

El reconocimiento de objetos en visión por computadora es la tarea de identificar qué objetos están presentes en una imagen o secuencia de video (Grimson (1990)). Aunque el reconocimiento de objetos ha sido un tópico de interés en la comunidad de visión computacional, la aplicación directa de los algoritmos a problemas de robótica no es siempre posible (Douillard et al. (2000)). Hay tres razones por las que ocurre lo antes mencionado. (i) Las aplicaciones robóticas requieren de reconocimiento de objetos en tiempo real. Aunque no existen algoritmos en tiempo real para la detección de rostros

(Viola y Jones (2004)), y el reconocimiento de objetos generales en tiempo real sigue en desarrollo. (ii) Los robots pueden estar equipados con diferentes tipos de sensores incluyendo de rango y visuales. La integración de estos sensores para el reconocimiento de objetos puede complementar la información visual. (iii) En la navegación, los robots observan al mismo objeto en diferentes posiciones y periodos de tiempo. Se espera que los algoritmos capaces de integrar observaciones de diferentes posiciones y tiempos sean más robustos en entornos complejos con iluminación variable y observaciones de los objetos en múltiples escalas (Douillard et al. (2000)).

El reconocimiento de objetos en imágenes presenta varios retos debidos en gran parte a las variaciones que presentan las imágenes. Algunas de estas variaciones pueden incluir:

- Oclusiones parciales de los objetos (ver Figura 2.1 (b)).
- Cambios del punto de vista de la imagen (ver Figura 2.1 (c)).
- Variaciones en la iluminación (ver Figura 2.1 (d)).
- Múltiples objetos en el fondo de la imagen (ver Figura 2.1 (e)).

En general, los sistemas de reconocimiento visual de objetos tienden a usar o bien características locales, o bien características globales (Lisin et al. (2005)). Una de las razones principales por las que no se combinan estos tipos de características es que tienen distintos formatos, i.e., las características globales tienen la habilidad de caracterizar a un objeto con un simple vector. Por su parte, las características locales pueden requerir de algoritmos de clasificación especializados que permitan manejar casos en los que hay un número variable de vectores de características por imagen.

En el trabajo de Lisin et al. (2005) los autores combinan características locales con características globales empleando técnicas de *stacking* y jerárquicas para el reconocimiento visual de clases de objetos. Las técnicas de *stacking* consisten en tener dos niveles de clasificación. En el primer nivel o nivel base de clasificación, se tiene un clasificador por cada característica empleada y las salidas de los clasificadores del nivel base son usadas como entradas en un clasificador de alto nivel que permite generalizar la clase sobre

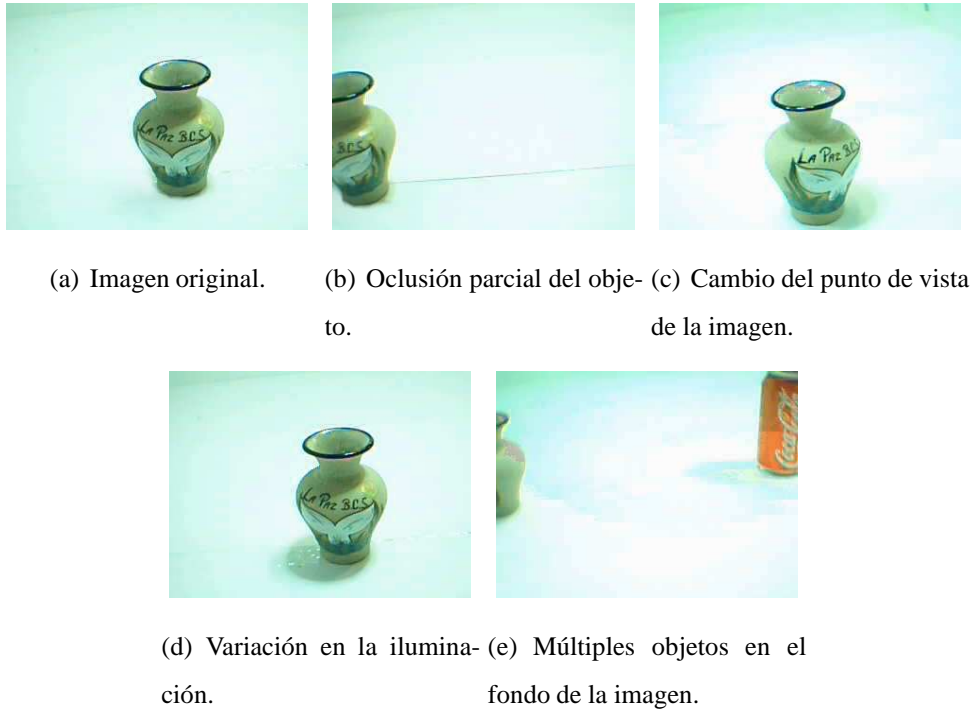


Figura 2.1: Variaciones que presentan las imágenes durante el reconocimiento de objetos. (a) Imagen original, de (b)-(d) se muestran algunas de las variaciones consideradas en la presente tesis para el reconocimiento de objetos, (e) variación no abordada en la tesis.

el espacio de salidas de los clasificadores del primer nivel. Por otro lado, al emplear técnicas jerárquicas para combinar características, se usa en el nivel más alto el clasificador más “rápido”, y aquellos elementos que no fueron clasificados en esta etapa entran en un segundo clasificador para su posterior clasificación. En el trabajo Lisin et al. (2005) los autores emplean dos niveles de clasificación empleando la técnica jerárquica. A diferencia de ellos, nosotros realizaremos una fusión Bayesiana de las probabilidades obtenidas en el reconocimiento visual de objetos empleando tanto las características locales como las globales de forma independiente.

A continuación presentamos brevemente en qué consisten las características locales y globales empleadas para el reconocimiento de objetos en la presente tesis, así como las técnicas aplicadas para su extracción. Posteriormente, en la sección 4.5.2 se detallará el proceso de obtención de las características locales y globales empleadas en el presente

trabajo.

2.5.1. Características Locales

Las características locales son descriptores de ciertas regiones de una imagen centradas alrededor de un punto de interés. Para cualquier objeto en una imagen pueden existir diversas características locales que son extraídas para proporcionar una descripción del mismo.

En el reconocimiento de objetos las características locales se extraen en una fase conocida como “entrenamiento” a partir de un conjunto de imágenes conocidas de forma análoga como imágenes de entrenamiento, las cuáles contienen al objeto de interés. Posteriormente las características extraídas pueden ser utilizadas para la identificación del objeto de interés en imágenes de prueba. Las imágenes de prueba son aquellas imágenes usadas para probar el reconocimiento de objetos una vez concluida la fase de entrenamiento y pueden contener objetos similares a los objetos de interés, u objetos distintos.

Las principales ventajas de las características locales son que no es necesaria una segmentación de los objetos en las imágenes, además de que son robustas a oclusiones en los objetos (Lisin et al. (2005)).

Es deseable que las características locales empleadas para la descripción de un objeto sean robustas a cambios de escala, rotación y cambios en la intensidad de iluminación. Es por ello que elegimos utilizar como características locales a los puntos SIFT que se describen brevemente a continuación.

Características SIFT

Las características SIFT (*Scale Invariant Feature Transform*) son características locales propuestas por Lowe (2004). Consisten básicamente de una colección de vectores con valores enteros, por lo general 128 valores. Las características SIFT son invariantes a translación de la imagen, escalamiento hasta cierto punto, rotación, y parcialmente robustas a cambios en la iluminación y distorsiones geométricas. Para imágenes planas las

características SIFT son robustas a rotaciones de 60° , mientras que para imágenes $3D$ la rotación máxima tolerada es de 20° aproximadamente (Lowe (2004)).

A continuación se describen las etapas empleadas para la extracción de las características SIFT:

1. **Detección de los extremos del espacio de escalas.** En esta etapa se identifican los puntos de la imagen que puedan ser reconocidos en distintas escalas de la misma. La detección de los puntos de la imagen que son invariantes a cambios de escala se logra buscando características estables a lo largo de un espacio de escalas (Witkin (1983)).

Para detectar puntos estables de forma eficiente a lo largo de un espacio de escalas, $L(x, y, \sigma)$, los autores propusieron en Lowe (1999) usar el extremo del espacio de escalas de la diferencia de funciones Gaussianas ($G(x, y, k\sigma) - G(x, y, \sigma)$) convolucionadas con la imagen original ($I(x, y)$), lo cual puede ser calculado como la diferencia de dos escalas cercanas de una misma imagen separadas por un factor constante k (ver expresión 2.1).

$$D(x, y, \sigma) = (G(x, y, k\sigma) - G(x, y, \sigma)) * I(x, y) = L(x, y, k\sigma) - L(x, y, \sigma) \quad (2.1)$$

donde $*$ es el operador de convolución en x y en y .

Las razones principales por las que los autores eligieron esta función Gaussiana son: (i) es una función particularmente eficiente de calcular y permite alisar a la imagen original en cierto grado (σ). (ii) La diferencia de Gaussianas se calcula mediante una simple substracción de imágenes (ver expresión 2.1).

En la figura 2.2 se muestra un ejemplo de la obtención de la diferencia de Gaussianas $D(x, y, \sigma)$. La imagen original es convolucionada con funciones Gaussianas para producir imágenes separadas por un factor constante k en el espacio de escalas, indicado en la columna de la izquierda. Los autores dividen cada octava del espacio de escalas en un número entero, s , de tal forma que $k = 2^{\frac{1}{s}}$. Se restan las imágenes

de escalas adyacentes para producir las imágenes de la diferencia de Gaussianas mostradas a la derecha. Una vez que una octava ha sido procesada, se re-calcula la imagen Gaussiana de tal forma que tenga el doble de su valor inicial σ .




Figura 2.2: Diferencia de Gaussianas de una imagen dada. Por cada octava del espacio de escalas, la imagen original es repetidamente convolucionada con las funciones Gaussianas para producir el conjunto de imágenes del espacio de escalas mostradas a la izquierda. Las imágenes Gaussianas adyacentes se restan entre sí para producir las imágenes de la diferencia de Gaussianas, mostradas a la derecha. Después de cada octava, la imagen Gaussiana es reducida por un factor de dos, y el proceso se repite. Tomada de Lowe (2004).

Para detectar los máximos y los mínimos locales de las diferencias de Gaussianas $D(x, y, \sigma)$, cada punto de la imagen se compara con sus ocho vecinos en la misma escala, y con sus nueve vecinos en las escalas de arriba y abajo. El punto se considera invariante si es mayor que todos sus vecinos o menor que todos ellos en el espacio de escalas. Este proceso se ilustra en la Figura 2.3.

2. **Localización de puntos clave.** En esta etapa se eliminan puntos de la lista de características que tengan bajo contraste (y que por lo tanto son sensibles a ruido) o que son pobremente localizados a lo largo de un borde en la imagen. Esto se consigue aplicando una función Laplaciana por cada punto encontrado en la etapa 1. Si el valor de la función Laplaciana para un punto dado está por debajo de un valor de




Figura 2.3: Los máximos y mínimos locales usando las diferencias de Gaussianas se detectan comparando un píxel (marcado con una X) con sus 26 vecinos en una región de 3×3 píxeles, tomando en cuenta la escala actual, i.e. la escala en la que se encuentra el píxel X , y las escalas adyacentes. Los vecinos se indican con círculos. Tomada de Lowe (2004).

umbral entonces se excluye dicho punto.

3. **Descriptor del punto de interés.** Finalmente se crean los descriptores de un punto de interés como sigue:

- a) Se selecciona una región alrededor del punto de interés (16×16 píxeles).
- b) Se calcula la magnitud del gradiente y la orientación por cada píxel de la región seleccionada usando diferencias de píxeles.
- c) Se divide la región en 4, y por cada sub-región de 4×4 píxeles se acumulan las orientaciones de los píxeles correspondientes en un histograma de orientaciones. El histograma de orientaciones corresponde al descriptor del punto consistente de $4 \times 4 \times 8 = 128$ valores. El número 8 indica el número de orientaciones posibles.

En la imagen 2.4 se muestra un ejemplo de detección de características SIFT en imágenes.

2.5.2. Características Globales

Las características globales, a diferencia de las características locales, toman en cuenta toda la imagen y extraen de ella una representación general. Ejemplos de características




Figura 2.4: Detección de características SIFT en imágenes. Los puntos SIFT se muestran como vectores que indican la escala, orientación y ubicación de cada punto.

globales son los histogramas de color, la forma o silueta, y la textura, entre otros.

Las principales ventajas de las características globales son la representación compacta de la imagen y la aplicación directa de algoritmos de clasificación como por ejemplo el algoritmo de los k-vecinos más cercanos (Mitchell (1997)). Las principales desventajas es que son sensibles a la oclusión y requieren una segmentación robusta para la detección de objetos.

La característica global empleada en el presente trabajo es la silueta promedio de los objetos observados por los robots. La silueta de un objeto se obtiene empleando sustracción del fondo y algunas operaciones morfológicas para eliminar ruido, en este caso nosotros usamos *closing* y *erosión*². La silueta promedio de un objeto de entrenamiento se obtiene a partir de las siluetas correspondientes a cada una de las imágenes capturadas por un robot de un mismo objeto. Estas siluetas deben tener un área superior al valor de un umbral, con lo cual se supone que el robot obtiene la silueta completa del objeto por cada imagen. Posteriormente se suman todas las siluetas completas del mismo objeto y se

²**Erosión:** Agranda huecos existentes en el objeto, reduce los bordes, elimina “islas” y remueve “penínsulas” angostas que puedan existir en el borde. **Dilatación:** Permite rellenar huecos en los objetos y expandir sus bordes, con lo cual se rellenan regiones angostas. **Closing:** Se forma por la combinación de las operaciones morfológicas de *dilatación* y *erosión* (Awcock y Thomas (1995)).

dividen entre el total de siluetas completas calculadas por el robot para ese objeto.

En la Figura 2.5 (b) se muestra un ejemplo de la silueta obtenida para el objeto de la figura 2.5 (a). En la figura 2.5 (c) se muestra la silueta promedio de una secuencia de 10 imágenes del mismo objeto.

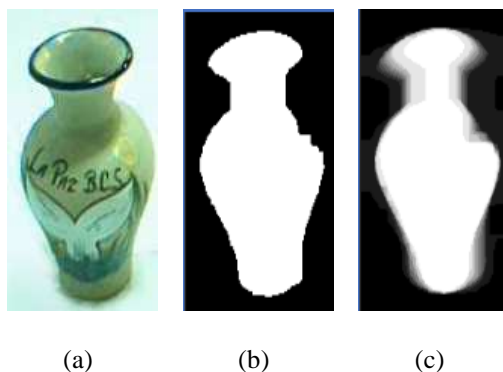


Figura 2.5: Ejemplos de la silueta y silueta promedio de un objeto. a) Imagen original, b) silueta del objeto, y c) silueta promedio de un bloque de imágenes del mismo objeto. La silueta promedio es la característica global empleada para ese objeto.

2.6. Análisis de componentes principales (PCA)

El análisis de componentes principales (PCA - *Principal Component Analysis* en inglés) tiene como objetivo encontrar un espacio o eigenespacio de dimensión menor que represente a los datos originales. El eigenespacio se obtiene identificando los eigenvectores (vectores propios) de la matriz de covarianza obtenida del conjunto de imágenes de entrenamiento. Los eigenvectores correspondientes a los eigenvalores (valores propios) no nulos de la matriz de covarianza forman una base ortonormal que refleja a las imágenes de entrenamiento en un espacio N-dimensional. N es la dimensión en la que se proyectan las imágenes de entrenamiento, y su valor máximo es igual al número de imágenes de entrenamiento empleadas, P .

El proceso de reconocimiento de objetos empleando el análisis de componentes principales se divide en dos fases: **entrenamiento** y **prueba**. En el resto de esta sección se

describen estas dos etapas.

2.6.1. Entrenamiento

A continuación realizamos una breve descripción del proceso de entrenamiento PCA empleando una imagen de entrenamiento por cada objeto distinto. Algunas de las variantes de este proceso de entrenamiento PCA involucran agregar más imágenes de entrenamiento por cada objeto distinto, como es el caso del trabajo presentado por Vicente et al. (2002).

1. Se crea una matriz ϕ que contenga por columna a las P imágenes de entrenamiento, donde cada columna de ϕ es de tamaño $N = w \times h$. Donde w y h son las dimensiones de las imágenes de entrenamiento.
2. Se obtiene la imagen promedio $\vec{m} = \frac{1}{P} \sum_{i=1}^P \phi^i$ de las imágenes de entrenamiento y se resta a cada una de las imágenes de entrenamiento ϕ^i , es decir, $\Phi^i = \phi^i - \vec{m}$.
3. Se obtiene la matriz de covarianza $\Omega' = \Phi^T \Phi$.
4. Se calculan los eigenvalores $\vec{\lambda}$ y los eigenvectores V' de la matriz de covarianza Ω' .
5. Se ordenan de mayor a menor los eigenvectores \hat{V} según el valor de los eigenvalores correspondientes.
6. Se proyecta cada imagen de entrenamiento centrada Φ^i en el nuevo subespacio, es decir, $\omega^i = \hat{V}^T \Phi^i$. El nuevo vector ω^i de la imagen proyectada tendrá tantas componentes como número de eigenvectores. En este punto cada imagen i se representa por el vector indicado en ω^i , y puede ser reconstruida empleando todos o sólo algunos de los eigenvectores \hat{V} con mayor o menor calidad.

2.6.2. Prueba

Para determinar que una nueva imagen ϕ se clasifica con alguna de las imágenes de entrenamiento ya proyectadas, es necesario centrar la imagen de prueba sustrayéndole la

imagen media \vec{m} , es decir, $\tilde{\phi} = \phi - \vec{m}$, y después proyectar la imagen centrada dentro del mismo eigenspacio definido por \hat{V} , es decir, $\vec{t} = \hat{V}^T \tilde{\phi}$.

La proyección obtenida \vec{t} de la imagen de prueba deberá compararse con cada una de las proyecciones de las imágenes de entrenamiento $\vec{\omega}$ empleando alguna medida de distancia. Generalmente se emplea la distancia Euclidiana y un umbral de aceptación para determinar a qué objeto de entrenamiento corresponde la nueva imagen.

En esta tesis usamos PCA sobre las siluetas promedio de los objetos de entrenamiento (ver sección 4.5.2.1).

2.7. Teorema de Bayes

El teorema de Bayes juega un papel predominante en robótica probabilística y en inferencia probabilística en general (Thrun et al. (2005)). En esta tesis usamos el teorema de Bayes para el reconocimiento de objetos al fusionar dos tipos de evidencia, la que proporciona el clasificador SIFT y la que proporciona el clasificador PCA al emplear tanto los conceptos individuales como los colectivos.

Sean X y Y variables aleatorias, y sean x y y valores específicos que las variables X y Y pueden adoptar. Si x es una cantidad que nos gustaría inferir a partir de y , lo que queremos calcular es la probabilidad de que una variable X tome un cierto valor x a partir del valor y que puede tomar otra variable Y , $P = (X = x | Y = y)$. Expresaremos lo anterior como $p(x|y)$. La regla de Bayes permite calcular la probabilidad posterior $p(x | y)$ a partir de la probabilidad condicional “inversa” $p(y | x)$ junto con las probabilidades *a priori* de las variables $p(x)$ y $p(y)$, como se indica en la expresión 2.2 (Murphy (2000)).

$$p(x | y) = \frac{p(y | x)p(x)}{p(y | x)p(x) + p(y | \neg x)p(\neg x)} \quad (2.2)$$

Si lo que se desea es inferir una cantidad x (la cual es la clase del objeto) a partir de los datos de más de un sensor (y y z , como pueden ser las características locales y globales empleadas en la presente tesis), $p(x | y, z)$, la regla de Bayes lo permite empleando la

probabilidad inversa de los valores de los sensores y y z dada la clase x , $p(y, z | x)$, donde las probabilidades inversas se pueden obtener de ejemplos de entrenamiento.

La regla de Bayes empleada en la presente tesis para realizar la fusión Bayesiana de las evidencias de dos sensores (P_P y P_S), es decir, para fusionar las probabilidades PCA y SIFT se muestra en la expresión (2.3).

$$p(P_{Cl} | P_P, P_S) = \frac{p(P_P, P_S | P_{Cl})p(P_{Cl})}{p(P_P, P_S | P_{Cl})p(P_{Cl}) + p(P_P, P_S | \neg P_{Cl})p(\neg P_{Cl})} \quad (2.3)$$

donde P_{Cl} es la clase, P_S es la probabilidad SIFT y P_P es la probabilidad PCA a fusionar. Si suponemos que las evidencias son independientes entre sí dada la clase, lo anterior se puede expresar como se indica en la expresión 2.4.

$$p(P_{Cl} | P_P, P_S) = \frac{p(P_P | P_{Cl})p(P_S | P_{Cl})p(P_{Cl})}{p(P_P | P_{Cl})p(P_S | P_{Cl})p(P_{Cl}) + p(P_P | \neg P_{Cl})p(P_S | \neg P_{Cl})p(\neg P_{Cl})} \quad (2.4)$$

2.8. Síntesis

En este capítulo se presentaron algunos conceptos básicos relacionados con el contenido de la tesis. Dado que el presente trabajo trata de aprendizaje de conceptos para sistemas multi-robot, se revisaron nociones importantes de sistemas multi-robot como lo son la interacción y la comunicación entre los miembros de un sistema multi-robot. Así mismo, se presentaron los principales factores que contribuyen en la incertidumbre en robótica móvil y en el aprendizaje en sistemas multi-robot. Además, se revisaron los conceptos básicos de reconocimiento de objetos así como las características locales y globales que serán utilizadas en los siguientes capítulos para el aprendizaje de conceptos. Posteriormente, se revisó el proceso de entrenamiento empleando PCA para el reconocimiento de objetos. Finalmente, se describió el teorema de Bayes empleado para fusionar características en el presente trabajo.

Capítulo 3

Estado del Arte

Por ser los más relevantes para nuestro trabajo nos enfocaremos en la revisión del estado del arte de sistemas multi-robot. En este capítulo discutiremos algunos de los trabajos más significativos en el área de aprendizaje en sistemas mono-robot y en aprendizaje cooperativo en sistemas multi-robot.

3.1. Aprendizaje en Sistemas Mono-Robot

En esta sección presentamos tres trabajos relacionados en donde interviene un solo robot y que tienen que ver con la tarea que se aborda en la presente tesis, es decir, aprendizaje de conceptos.

Steels y Kaplan (2001) prueban tres tipos de aprendizaje para hacer que un robot físico AIBO adquiriera sus primeras “palabras”, es decir, aprenda una relación entre los objetos que observa con su cámara y su nombre correspondiente. Las palabras son aprendidas por el robot a través de “juegos del lenguaje”¹. El robot AIBO está dotado con las capacidades necesarias para el reconocimiento de voz, para emitir sonidos, para adquirir imágenes y para operar de forma autónoma, principalmente. Los experimentos consistieron en probar tres tipos de aprendizaje: aprendizaje supervisado, aprendizaje semi-supervisado y aprendizaje no-supervisado. En el aprendizaje supervisado los autores suponen mayor

¹Los “juegos del lenguaje” consisten en realizar preguntas y respuestas sobre un objeto en particular.

interacción entre el robot y el experto respecto a la interacción realizada empleado aprendizaje semi-supervisado, sin embargo ambos tipos son similares entre sí. En todos los experimentos el robot debía aprender la relación entre tres tipos de objetos distintos: una “Pelota roja”, un juguete llamado “Smiley” y un AIBO de juguete llamado “Poo-chi”, y sus respectivos nombres, dados por el experto.

Los autores utilizan un método de clasificación basado en instancias para representar los datos adquiridos por el robot (Mel (1997)). La representación que el robot tiene de los tres objetos consiste en realizar un pre-procesamiento a cada una de las imágenes capturadas para evitar que cambios en la iluminación afecten el reconocimiento. Cada imagen se representa por un histograma de color de $16 \times 16 = 256$ valores. En la Figura 3.1 se muestra un objeto y su correspondiente histograma. Una vez que se almacenan diferentes vistas de un mismo objeto, se clasifican empleando el algoritmo del vecino más cercano (Mitchell (1997)).




Figura 3.1: Ejemplo de una imagen capturada por el robot y su histograma de color asociado. Tomada de Steels y Kaplan (2001).

En el aprendizaje supervisado, el experto presenta al robot los objetos indicando los nombres correspondientes (ver Figura 3.2(a)). Si el robot repite correctamente el nombre del objeto que se encuentra viendo a través de su cámara de video, el experto da un estímulo positivo, de lo contrario el experto indica un estímulo negativo y repite el nombre del objeto. En el aprendizaje semi-supervisado (ver Figura 3.2(b)), el robot de manera autónoma se desplaza por el ambiente y cuando se encuentra con alguno de los

tres objetos antes mencionados, el experto pronuncia el nombre respectivo del objeto observado. En el aprendizaje no-supervisado (ver Figura 3.2(c)), el experto no da ningún tipo de retroalimentación al robot y deja que éste detecte las relaciones entre los distintos objetos.

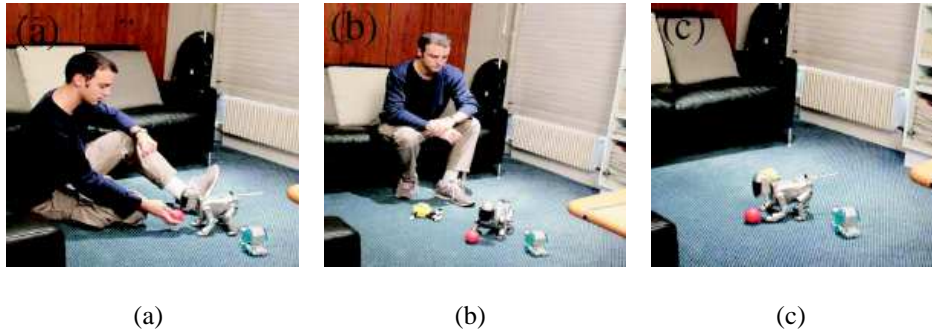


Figura 3.2: Distintos grados de interacción social. a) Interacción fuerte (aprendizaje supervisado), b) aprendizaje observacional con supervisión (aprendizaje semi-supervisado), c) aprendizaje no-supervisado. Tomada de Steels y Kaplan (2001).

En todos los experimentos realizados se variaron las condiciones de iluminación y el fondo. Los resultados se obtuvieron empleando el algoritmo del vecino más cercano e indicaron que el aprendizaje supervisado arroja mejores resultados que los otros dos tipos de aprendizaje debido a la fuerte interacción entre el robot y el experto. Los resultados obtenidos con el aprendizaje supervisado son: 66 % de aciertos en la clasificación del objeto “Poo-chi”, 92 % para el objeto “Pelota roja” y 86 % para el objeto “Smiley”. Los resultados obtenidos con el aprendizaje semi-supervisado son: 40 % para “Poo-chi”, 84 % para “Pelota roja” y 54 % para “Smiley”. Los resultados en el aprendizaje no-supervisado arrojaron ocho clases distintas, con las cuales no fue posible determinar ninguna relación entre los distintos objetos. En este caso se utilizó el método de *clustering* EM (*Expectation-Maximization* Mitchell (1997)) pues no se supone que el robot conoce de antemano el número de categorías u objetos a aprender que están ocultas en los datos. Por lo anterior se observa que sin la influencia del lenguaje o de cierta supervisión, el algoritmo de aprendizaje no-supervisado no puede detectar las relaciones existentes en los datos, ni aprender

los conceptos requeridos.

En el referido trabajo los autores representan a cada objeto con un vector de 256 valores, lo cual permite el manejo de distintas vistas de un mismo objeto de forma rápida y compacta para su posterior clasificación. Uno de las principales inconvenientes de este trabajo es que al no extraer suficiente evidencia de las imágenes, no es posible detectar ninguna relación entre los distintos objetos empleando el aprendizaje no-supervisado.

En el trabajo de Ekvall et al. (2006) los autores usan diferentes técnicas de aprendizaje para adquirir automáticamente información semántica y espacial del ambiente en un escenario de robots de servicio. En este trabajo, un robot autónomo y móvil navega en un ambiente doméstico, construye un mapa mientras se va moviendo, localiza su posición en el mapa, reconoce los objetos que va observando durante su recorrido y los representa en el mapa.

Los objetos se representan por dos partes: (i) por un método basado en apariencia que permite detectar objetos alejados en una imagen RFCH (textitReceptive Field Cooccurrence Histograms), y (ii) por sus características SIFT.

En este trabajo los autores resuelven el problema de obtener características locales confiables aún cuando los objetos se encuentran alejados de la cámara. Para resolver dicho problema, los autores emplean una cámara con *pan-tilt-zoom* y un método global para generar hipótesis. Los autores usan RFCH (Ekvall y Kragic (2005)) para generar hipótesis sobre las posibles ubicaciones de un objeto en una imagen, y por cada región detectada sobre la imagen se realiza un acercamiento o *zoom-in*. Posteriormente, se emplea un método basado en puntos SIFT que permite el reconocimiento de objetos.

En el referido trabajo, los objetos de entrenamiento se aprenden por demostración humana. En primer lugar, se instruye al robot para capturar una imagen del fondo del ambiente sin objetos presentes en él. Posteriormente, el usuario coloca al objeto de entrenamiento en frente de la cámara del robot y mediante diferencias de imágenes el robot segmenta al objeto del fondo. En este punto se emplea una serie de operadores morfológicos para segmentar mejor al objeto (*erosión - dilatación - erosión*)². Finalmente,

se obtienen las características SIFT del objeto segmentado. Si durante el entrenamiento ocurren errores en la segmentación, es decir, si parte del fondo es visible en la imagen durante el entrenamiento, dicha información será aprendida y por lo tanto se incrementará el número de falsos positivos en el reconocimiento de objetos. Para aprender las características globales RFCH del objeto segmentado, es necesario extraer características visuales, por ejemplo, la magnitud del gradiente y una respuesta Laplaciana, que son usadas para construir el RFCH. Los RFCH permiten capturar muchas de las propiedades geométricas de un objeto.

En la tarea de reconocimiento de objetos, se produce una hipótesis escaneando la imagen de prueba con ventanas de búsqueda pequeñas. Por cada ventana se construye un RFCH y se compara con el RFCH almacenado del objeto a buscar. Si coinciden ambos histogramas, se realiza un acercamiento o *zoom-in* en la región explorada para obtener sus características SIFT y así compararlas con las características SIFT almacenadas del objeto para determinar la clase del mismo. Por cada objeto, los autores miden el tiempo promedio para la detección, el promedio total del tiempo de búsqueda, y el número de detecciones.

En el trabajo de Mitri et al. (2004), los autores presentan un esquema para la detección de pelotas de forma invariante al color en el contexto *RoboCup*. Para asegurar la invarianza al color de las imágenes de entrada, se elimina la información de color de las imágenes de entrenamiento que representan a las pelotas. Para realizar lo anterior, los autores usan filtros lineales que permiten detectar bordes en las imágenes.

En la figura 3.3 (a la izquierda) se muestran las once características que se usan en el entrenamiento, es decir, características de borde, línea, diagonal y centro. Las características se calculan en una imagen de entrada usando la imagen integral. La representación de las imágenes integrales $I(x, y)$ permite el cálculo de una característica rectangular cuyo valor es (x, y) y su alto y ancho es (h, w) .

Tanto para la detección como para el entrenamiento, es necesario un conjunto de imágenes clasificadas como positivas o negativas, de las cuales se extraen sus características para posteriormente en el reconocimiento determinar la clase de las imágenes de




Figura 3.3: Características usadas para la representación de objetos. A la izquierda: Características de borde, línea, diagonal y centro. A la derecha: En la región sobreada se ilustra el cálculo de los valores de una característica basándose en los cuatro rectángulos superiores. Tomada de Mitri et al. (2004).

prueba. La clase de las imágenes de prueba se determina clasificando las características detectadas de dicha imagen dadas las características previamente aprendidas. Estas características sirven como entrada para un clasificador AdaBoost, que construye una cascada de clasificación y de árboles de regresión (CARTs).

El sistema es capaz de detectar diferentes pelotas de soccer en el ambiente RoboCup y en otros ambientes. El método resultante es confiable y lo suficientemente rápido para clasificar objetos en tiempo real. Los autores miden los porcentajes de clasificación con base en el número de objetos bien clasificados sobre el total objetos; el porcentaje de objetos no detectados; y el número de falsos positivos en cada prueba.

3.2. Aprendizaje Cooperativo en Sistemas

Multi-Robot

En esta sección nos enfocamos en la revisión de trabajos relacionados en el aprendizaje cooperativo de conceptos en el cual cada robot del sistema tiene su propio proceso de aprendizaje que le permite adaptar lo aprendido en el contexto de múltiples robots “co-adaptándose” entre sí con otros robots sobre los cuales no tienen control alguno, es decir, en el aprendizaje concurrente. A continuación presentamos algunos de los trabajos

relacionados con las áreas de problemas de asignación de créditos y modelado de otros agentes del aprendizaje cooperativo.

3.2.1. Problemas de asignación de créditos y modelado de agentes

Fernández et al. (2005) mostraron cómo abordar una tarea de Observación Cooperativa Multi-robot de Múltiples Objetivos en Movimiento (CMOMMT - por sus siglas en inglés *Cooperative Multi-robot Observation of Multiple Moving Targets*) aplicando aprendizaje por refuerzo.

Los autores definieron un conjunto de acciones discretas, e.g., ir al norte, ir al noreste, ir al este, etc., y limitaron el espacio de estados usando atributos que consideraron necesarios, e.g., información del objetivo observado más cercano, información del objetivo observado más alejado, así como información del robot más cercano. La información adquirida corresponde generalmente a las posiciones en las que se encuentran los objetivos y los robots vecinos. Los autores desarrollaron una función de aprendizaje por refuerzo para aprender comportamientos en la cual va implícita la colaboración. Se emplean diferentes criterios para dar los refuerzos, como el número de objetivos observados (refuerzo positivo), y si otros robots tienen el mismo rango de vista (refuerzo negativo). Este último criterio trata de proporcionar el comportamiento colaborativo, evitando que un robot tenga el mismo rango visual que otro robot durante la tarea de observación y resultando en una acción conjunta y complementaria.

Los autores presentan dos modos de aprendizaje durante la fase de experimentación en la cual emplean diez robots móviles equipados con una cámara de video cada uno y el número de objetivos a observar es diez. En el primer experimento sólo un robot aprende (*team learning*), posteriormente se comparte el conocimiento adquirido por dicho robot al resto de los robots del sistema multi-robot; en el segundo experimento todos los robots tienen la capacidad de aprender a focalizar objetivos distintos (*concurrent learning*).

Matarić (1997) aborda el problema de la asignación de créditos en aprendizaje por

refuerzo empleando un método denominado *shaped reinforcement*, en el cual se usan funciones heterogéneas de refuerzos y estimadores progresivos. La autora valida su método en la tarea de recolección de objetos (*foraging*) usando un grupo de cuatro robots móviles cuyo objetivo es recorrer un ambiente semi-estructurado, buscando y recolectando objetos (discos de *hockey*) para su posterior colocación en cierto lugar del ambiente conocido como “hogar” (*home*). Ver Figura 3.4.



Figura 3.4: Búsqueda y recolección de objetos empleando un sistema multi-robot. El objetivo de la tarea es recolectar el mayor número de objetos y colocarlos en una zona del ambiente conocida como “hogar”, en la esquina superior derecha de la imagen. Tomado de Matarić (1997).

Para la asignación del refuerzo, la autora usa dos estimadores progresivos. El primer estimador se asocia con minimizar la interferencia que se produce cuando un robot está cerca de otro. Se da un refuerzo positivo si el comportamiento que está siendo ejecutado tiene el efecto de incrementar la distancia física al robot vecino más cercano. El segundo estimador progresivo se asocia con un estado conocido como *homing*, el cual se inicia siempre que un robot sujete un disco. Si la distancia al “hogar” disminuye, el robot recibe refuerzo positivo. En otro caso, el robot es penalizado o se le da un refuerzo positivo mínimo.

La recompensa total se obtiene de una combinación de todos los refuerzos. Se compara el desempeño de tres métodos en los que se varía la definición de la función de recompensa usando grupos de 3 y 4 robots. Los mejores resultados se observaron al combinar refuerzos positivos, negativos y estimadores progresivos.

En los dos trabajos antes mencionados, los autores resuelven las tareas correspondientes empleando aprendizaje concurrente, y lo que cada robot aprende son comportamientos cooperativos a través del uso del aprendizaje por refuerzo en cada robot del sistema.

En ninguno de los dos trabajos antes mencionados hay algún tipo de comunicación entre los robots del sistema, es por ello que se requiere del aprendizaje por refuerzo para que los robots sean capaces de aprender los comportamientos cooperativos tomando en cuenta únicamente la información percibida por sus propios sensores.

A continuación presentamos algunos de los trabajos relacionados con el área de dinámica del aprendizaje.

3.2.2. Dinámica del aprendizaje

Hasta donde sabemos, hay pocos trabajos que abordan el aprendizaje cooperativo de conceptos empleando sistemas multi-robot.

En el trabajo realizado por O'Beirne y Schukat (2004) se propone un método para realizar la exploración y el reconocimiento de objetos de un ambiente empleando un sistema multi-robot cooperativo. El método propuesto por estos autores permite representar el ambiente empleando rejillas de ocupación, donde cada rejilla contiene la probabilidad de estar ocupada. Cada rejilla ocupada contiene una referencia a un objeto que se encuentra modelado en detalle en una base de datos de objetos. Por lo tanto, el método de O'Beirne y Schukat no sólo involucra el indicar si ciertas regiones del ambiente se encuentran ocupadas o no, sino que también permite identificar a los objetos localizados en el ambiente, obteniendo con esto una representación detallada del mismo. Además, se emplea a los robots del sistema multi-robot para realizar la segmentación, el modelado y la clasificación de los objetos que se encuentran en el ambiente.

El método propuesto de modelado y reconocimiento de objetos consiste en lo siguiente:

1. Se combinan diferentes vistas u observaciones de uno o varios objetos desde dis-

tintos ángulos, donde cada vista distinta es obtenida por un robot del sistema (ver Figura 3.5).

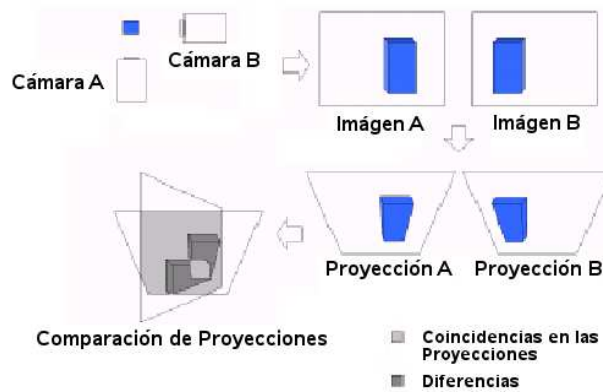


Figura 3.5: En la imagen inferior izquierda se muestra la combinación de las proyecciones de dos vistas de un objeto. En gris claro se muestran las coincidencias entre las vistas, y en gris oscuro se muestran las diferencias en las proyecciones. Tomada de O’Beirne y Schukat (2004).

2. Se utilizan filtros Kalman (Forsyth y Ponce (2003)) para realizar la segmentación de los objetos entre las distintas vistas capturadas por los robots basándose en color, textura y forma (ver figura 3.6). Esto permite incrementar la probabilidad de segmentar objetos como entidades distintas en ambientes con más de un objeto.

En la figura 3.6 se muestra un ejemplo de segmentación de un objeto usando filtros Kalman. En el primer nivel (columna del extremo izquierdo), se muestran las imágenes capturadas por dos robots. En el segundo nivel (columna del centro), se muestra el proceso de segmentación de los objetos realizado de forma individual. En este nivel el robot con la cámara A tomó a los dos objetos como uno solo, mientras que el robot con la cámara B los distinguió correctamente. En el tercer nivel (columna del extremo derecho), se determina que hay dos objetos en escena.

3. Se utiliza Análisis de Componentes Principales (PCA) para realizar el reconocimiento de objetos, i.e., simplemente se detecta la clase más cercana para atribuir




Figura 3.6: Segmentación de la imagen usando filtros Kalman. Tomada de O'Beirne y Schukat (2004).

una clase a un objeto.

4. Se modela la forma de los objetos en 3D usando la Forma de la Silueta (SFS - por sus siglas en inglés). Esta técnica permite examinar a los objetos desde distintos ángulos y calcular su forma (ver Figura 3.7). En caso de que un objeto sólo pueda ser visto desde un número limitado de ángulos, se usa interpolación para completar el modelo.

Durante la exploración del ambiente, los robots del sistema multi-robot detectan objetos que se encuentran dentro del ambiente por medio de su apariencia y forma. En la parte de detección de objetos, los robots deben segmentar a los objetos de forma precisa. Posteriormente se realiza el reconocimiento de los objetos segmentados empleando una base de objetos conocidos, y en caso de que algún objeto no pueda reconocerse con la base de objetos, éste es modelado y aprendido en términos de su forma y apariencia.

En el mismo trabajo de O'Beirne y Schukat (2004), se tiene a un robot como coordinador central para combinar los datos visuales adquiridos por los robots del sistema multi-robot. En dicho trabajo los autores emplean la forma 3D de los objetos y su apariencia para representar a los distintos objetos que se encuentran en el ambiente. A esta representación también se le conoce como concepto. Además, en el trabajo de O'Beirne




Figura 3.7: Técnica de Forma de la Silueta (*Shape From Silhouette*), permite examinar a los objetos desde distintos ángulos y calcular su forma. Tomada de O’Beirne y Schukat (2004).

y Schukat (2004), los robots combinan diferentes vistas de uno o varios objetos para aprender cooperativamente sus conceptos. Sin embargo en el referido trabajo no se hace un análisis para formar conceptos colectivos, por lo cual se corre el riesgo de “sobre-representar” a un mismo objeto en más de un concepto.

En el trabajo de Montesano y Montano (2003) los autores abordan el problema del reconocimiento de objetos que se encuentran en movimiento empleando un sistema multi-robot basándose en información cinemática. Los autores argumentan que el reconocimiento de objetos en movimiento usando características visuales como color, textura, forma y tamaño es más complejo que el reconocimiento de objetos estáticos, debido a que los objetos que se encuentran en movimiento usualmente no pertenecen al sistema multi-robot.

La idea básica de su trabajo es que si el mismo objeto es visto por dos robots distintos, las trayectorias y por tanto la información cinemática observada por cada robot deben ser similares. Por lo tanto, la ubicación y la velocidad de los objetos en movimiento son usadas como características para el reconocimiento de objetos.

El método usa un método Bayesiano y se basa en hacer corresponder los mapas

dinámicos de los objetos construidos por cada robot del sistema multi-robot. Los mapas dinámicos de los objetos contienen las posiciones relativas de los objetos en movimiento y sus velocidades en un tiempo dado.

En la sección 5.5 del capítulo de experimentos y resultados, se presenta una comparación con algunos de los trabajos relacionados.

3.3. Síntesis

En este capítulo nos enfocamos en la revisión del estado del arte en el área de aprendizaje en sistemas mono-robot y multi-robot.

En el área de aprendizaje cooperativo en sistemas multi-robot se detectaron dos tipos de aprendizaje principalmente, el aprendizaje individual y el concurrente. En el primero es un solo robot el que aprende descubriendo un conjunto de comportamientos para el grupo de robots completo. En el aprendizaje concurrente cada robot tiene su propio proceso de aprendizaje que le permite adaptar sus comportamientos en un contexto de múltiples robots.

Capítulo 4

Método propuesto

Dado que el objetivo general de esta tesis es el aprendizaje cooperativo de conceptos para sistemas multi-robot, en este capítulo se da una descripción de los cuatro módulos de los que consta cada robot miembro del sistema multi-robot, los cuales permiten la obtención de los conceptos colectivos. Posteriormente se describe el esquema general del sistema multi-robot propuesto, seguido de la descripción de los elementos necesarios para el desarrollo del aprendizaje cooperativo de conceptos propuesto.

4.1. Descripción general del ambiente

Para el desarrollo del método propuesto se empleó un ambiente semi-estructurado con forma rectangular de 2.00×2.60 metros. El ambiente está cubierto por un fondo blanco y uniforme que permite segmentar y detectar rápidamente objetos vistos por los robots con su cámara de video mediante técnicas de sustracción de fondo. En el ambiente se encuentran distribuidos diferentes objetos, de tal forma que un robot no pueda capturar con su cámara de video a dos o más objetos de forma simultánea. El número de objetos que pueden presentarse en el ambiente es variable tanto para el entrenamiento como para el reconocimiento de objetos.

Decimos que el ambiente es semi-estructurado por tres razones: (i) los robots no conocen la ubicación explícita de los objetos observados, es decir, desconocen tanto la dis-

tancia a la que se encuentran los objetos de los robots como la orientación de los mismos respecto a los robots. La distancia mínima y máxima en la que un robot puede observar a un objeto completo y extraer características de él con su cámara de video se encuentra entre 0.20 m y 1.00 m aproximadamente. (ii) Los robots no conocen el orden de aparición de los objetos, es decir, a pesar de que cada robot sigue una trayectoria previamente definida, los robots desconocen tanto el número como el tipo de objetos que van a observar durante su recorrido por el ambiente. (iii) Los robots desconocen la clase de los objetos observados, es decir, son los robots los que detectan las clases entre los distintos objetos que cada uno observa durante el entrenamiento.

En la figura 4.1 se muestra el ambiente del sistema multi-robot con un ejemplo de las posibles ubicaciones de tres de los objetos de prueba.



Figura 4.1: Ambiente del sistema multi-robot. Se presentan tres objetos distintos colocados en línea recta separados por una distancia uniforme.

4.2. Tipos de objetos

En el presente trabajo se distingue a los objetos por su forma, que es una característica global, y por sus características locales SIFT (cf. sección 2.5.1). La razón de emplear estos dos tipos de características para representar a un objeto dado, es decir, para obtener un concepto que defina al objeto, es que ambas características se complementan entre sí, ya

que cada grupo de ellas pone énfasis en propiedades específicas de un objeto pero usualmente son insuficientes y fallan en distintas situaciones. Por ejemplo, la representación de la forma de los objetos depende directamente de una correcta segmentación. Además, si dos o más objetos distintos tienen formas similares, la forma no proporciona suficiente evidencia para una adecuada clasificación. Por otro lado, empleando únicamente características SIFT, pueden producirse confusiones cuando se tengan distintos objetos cuya textura sea similar o cuando no sea posible extraer características SIFT de ellos.

Por la silueta o forma de los objetos, es decir, por sus características globales, se puede distinguir entre los distintos objetos como sigue:

1. **Objetos simétricos verticalmente:** Son aquellos objetos cuya forma o contorno se conservan independientemente del punto de vista en el que algún robot capture imágenes de ellos. Estos objetos son fáciles de identificar usando distintas vistas de ellos siempre que las siluetas de objetos distintos sean distinguibles entre sí. Cabe señalar que en los experimentos veremos también objetos diferentes con siluetas iguales. Un ejemplo de este tipo de objetos se muestra en la figura 4.2.

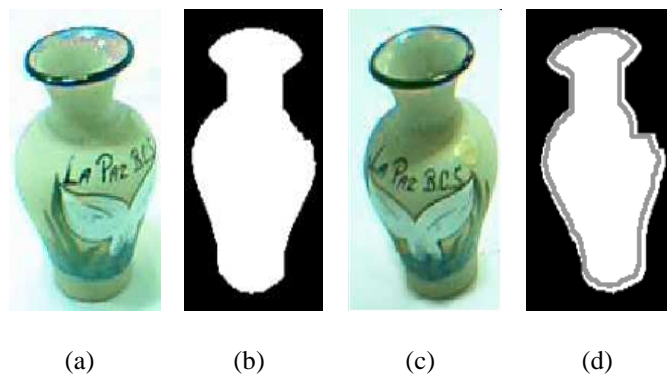


Figura 4.2: Ejemplo de un objeto simétrico verticalmente. (a) Vista 1 del objeto florero y (b) su correspondiente silueta, (c) vista n del objeto florero y (d) su correspondiente silueta.

2. **Objetos no simétricos verticalmente:** Son aquellos objetos cuya forma o contorno cambia dependiendo del punto de vista en el que algún robot los está observando,

por ejemplo para nuestro caso el objeto delfín (ver figura 4.3). En este tipo de objetos es difícil identificar que se trata de un mismo objeto si se tienen vistas distintas de él.

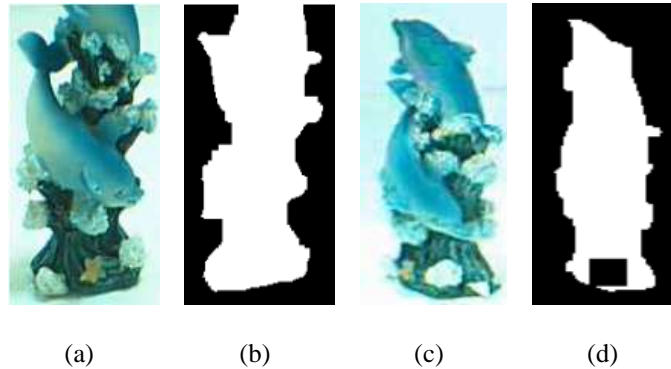


Figura 4.3: Ejemplo de un objeto no simétrico verticalmente. (a) Vista 1 del objeto delfín y (b) su correspondiente silueta, (c) vista m del objeto delfín y (d) su correspondiente silueta. Como puede apreciarse en las siluetas del objeto delfín correspondientes a distintas vistas del mismo objeto, las siluetas del objeto son distintas entre sí.

Por las características locales podemos distinguir a los objetos como sigue:

1. **Objetos recurrentes:** Son aquellos objetos cuya textura se repite a lo ancho de la superficie del objeto. La principal característica es que independientemente de la vista en la que un robot capture al objeto, las características locales extraídas de éste serán similares entre las distintas vistas posibles del mismo (ver figura 4.4 (a)). Estos objetos son fáciles de identificar desde diferentes vistas siempre que se obtengan características SIFT diferentes para objetos diferentes. Cabe señalar que en los experimentos veremos también texturas iguales en objetos distintos.
2. **Objetos no recurrentes:** Son aquellos objetos en los que cambia prácticamente por completo la textura del objeto dependiendo de la vista capturada del mismo. En este tipo de objetos se considera que sólo pocas vistas consecutivas de éstos objetos coinciden entre sí. Por vista consecutiva que coincide con otra previamente

capturada entendemos que el robot observa al mismo objeto con un ángulo máximo de rotación de 10° aproximadamente. Si el ángulo de rotación del objeto es mayor a los 10° , el robot no será capaz de detectar que se encuentra observando al mismo objeto. En general, estos objetos son objetos difíciles de detectar cuando no hay traslape entre vistas consecutivas. Un ejemplo de este tipo de objetos se muestra en la figura 4.4 (b).

3. **Objetos sin características locales:** Son objetos lisos. En esta clase también entran aquellos objetos que tienen regiones con poca textura, pues la cantidad de características locales a extraer de estos objetos es prácticamente nula (ver figura 4.4 (c)). De estos objetos no es posible extraer características SIFT que los representen, es decir, SIFT no funciona para el reconocimiento de este tipo de objetos.




Figura 4.4: Tipos de objetos detectados por sus características locales. a) Objeto recurrente, b) objeto no recurrente y c) objeto sin características locales.

En este trabajo probamos diferentes tipos de objetos en los que combinamos objetos simétricos verticalmente con los tres tipos de objetos detectados empleando las características locales SIFT, es decir, simétricos-recurrentes, simétricos-no recurrentes y simétricos-sin características. También utilizamos objetos no simétricos cuyas características locales son del tipo no recurrente.

4.3. Composición del sistema multi-robot

El sistema multi-robot consta de dos robots homogéneos *Koala* de K-TEAM equipados con una cámara web cuya resolución es de 320×240 píxeles (ver figura 4.5). Para realizar el procesamiento cada robot miembro del sistema multi-robot utiliza una computadora portátil de 1 GB de memoria RAM. Además, los robots tienen la capacidad de comunicarse de forma directa a través de una red inalámbrica *WiFi* sin necesidad de un servidor externo.



Figura 4.5: Los dos robots miembros del sistema multi-robot.

Para que cada uno de los miembros del sistema multi-robot sea capaz de aprender conceptos de forma individual y cooperativa, cada uno consta de cuatro módulos: 1) el módulo de entrenamiento individual, 2) el módulo de comunicación, 3) el módulo de análisis y fusión de conceptos, y 4) el módulo de reconocimiento. Los módulos antes mencionados se ejecutan en cada robot del sistema en una computadora portátil conectada a través del puerto serial al robot correspondiente.

A continuación se explica brevemente el funcionamiento de cada uno de los módulos de los que consta cada robot del sistema.

1. **Módulo de entrenamiento individual:** Es el encargado de adquirir imágenes de cada uno de los objetos siguiendo una trayectoria predefinida. En esta parte se representa a cada objeto visto por el robot con un concepto que consiste de dos partes, la parte que describe la forma del objeto, es decir, el concepto individual PCA, y la parte que describe las características locales del objeto, es decir, el concepto

individual SIFT. A lo aprendido en esta etapa del entrenamiento se le conoce como conceptos individuales del robot, y los robots asumen que posiblemente verán objetos de entrenamiento repetidos. La información adquirida en este módulo es utilizada en todos los módulos subsecuentes del robot.

2. **Módulo de comunicación:** El módulo de comunicación es el encargado de transmitir y recibir información de un robot a otro a través de una red inalámbrica. La transmisión se realiza directamente de un robot a otro sin necesidad de un servidor externo. Esto les permite a los robots miembros del sistema multi-robot compartir entre ellos sus conceptos individuales.
3. **Módulo de análisis y fusión de conceptos:** En este módulo se utilizan los conceptos individuales aprendidos en el módulo de entrenamiento individual y los conceptos individuales compartidos con el módulo de comunicación. A partir de los conceptos individuales se genera un concepto colectivo mediante la búsqueda de información coincidente, complementaria y confusa (cf. sección 4.7).
4. **Módulo de reconocimiento:** En este módulo se utilizan los conceptos individuales adquiridos por el módulo de entrenamiento individual o los conceptos colectivos obtenidos por el módulo de análisis y fusión de conceptos para el reconocimiento de objetos en línea.

4.4. Esquema general del sistema multi-robot

En la figura 4.6 se presenta el esquema general del sistema multi-robot. A continuación se detalla dicho esquema.

En la etapa inicial cada robot obtiene de manera autónoma una secuencia de imágenes de entrenamiento de los distintos objetos observados. La secuencia de imágenes que cada robot captura con su cámara es obtenida a lo largo de la trayectoria seguida por el robot definida previamente.

La etapa de entrenamiento se realiza de forma individual, es decir, por separado por cada miembro del sistema multi-robot. En esta etapa los robots utilizan las imágenes de entrenamiento capturadas y obtienen una representación individual o concepto individual por cada objeto de entrenamiento distinto. Un concepto consiste de dos partes, la parte que representa la forma del objeto, y la parte que representa las características locales del objeto (ver apéndice A).

Una vez obtenidos los conceptos individuales, cada robot comparte con los otros robots sus conceptos a través de una red inalámbrica *WiFi*, de tal forma que cada robot recibe los conceptos de los otros robots y envía a ellos los suyos.

El análisis de las representaciones o conceptos individuales se realiza de forma individual en cada miembro del sistema multi-robot empleando los conceptos propios y compartidos por los robots del sistema. Durante el análisis se determina si hay información coincidente, complementaria o confusa entre los distintos conceptos aprendidos por los robots del sistema, y dependiendo del caso determinado a partir del tipo de información detectada será el criterio a tomar por cada robot respecto a qué hacer con la información.

Finalmente, se aplican los conceptos individuales y cooperativos en una tarea de reconocimiento de objetos.

4.5. Entrenamiento individual

En el entrenamiento individual cada robot del sistema multi-robot aprende conceptos individuales tanto en línea como fuera de línea mientras se encuentra recorriendo una trayectoria previamente definida. Durante el entrenamiento individual los robots no tienen conocimiento *a priori* del número o del tipo de los objetos a aprender. El proceso de entrenamiento individual consiste básicamente de tres partes: detección de objetos, extracción de características y entrenamiento individual.

Los conceptos individuales de los objetos se forman por dos partes: por los conceptos individuales PCA y por los conceptos individuales SIFT.

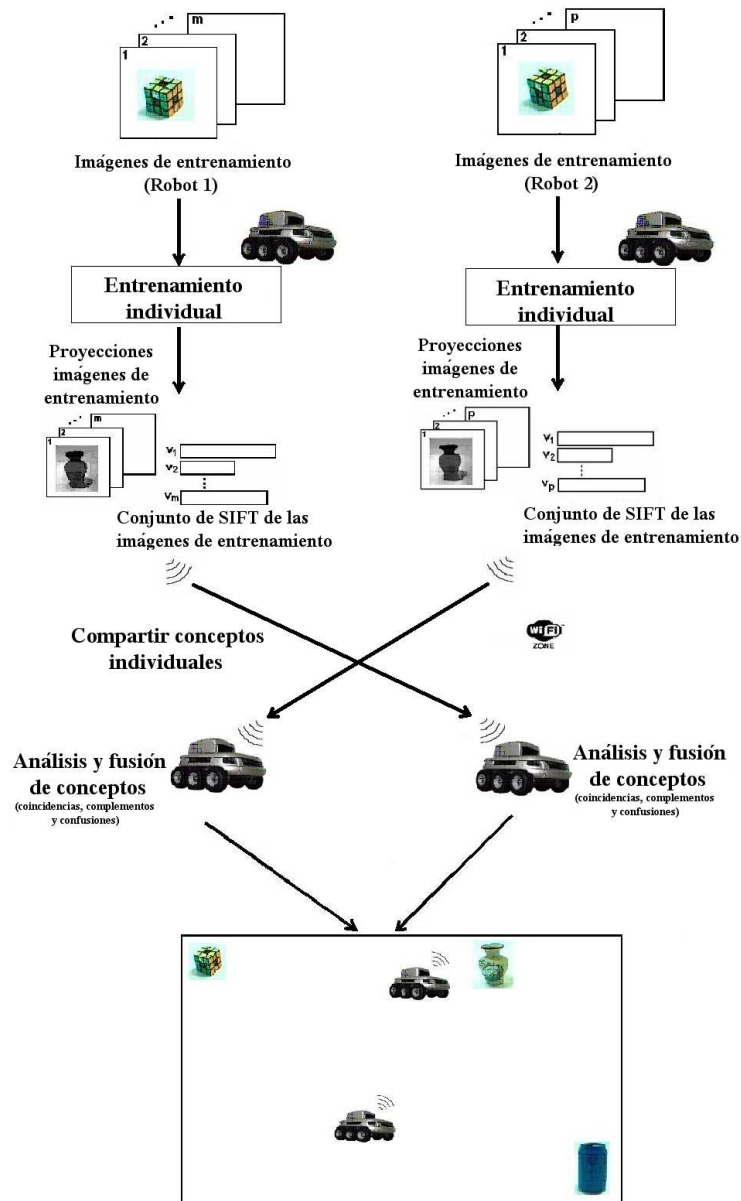


Figura 4.6: Esquema general del sistema multi-robot.

4.5.1. Detección de objetos

En la detección de objetos cada robot aplica una fase de preprocesamiento a las imágenes capturadas por ellos mismos. La fase de detección de objetos permite a los robots determinar la presencia o no de algún objeto en la imagen.

El preprocesamiento de imágenes tiene como finalidad obtener en una imagen de di-

mensiones fijas, por ejemplo, de 200×100 píxeles, al objeto centrado y segmentado contenido en la imagen original del robot.

El preprocesamiento es necesario debido a que los miembros del sistema multi-robot pueden observar a los distintos objetos desde diferentes distancias y posiciones, lo cuál se refleja en las imágenes capturadas por los robots como objetos a distintas escalas y ubicaciones a lo largo de la imagen original. Con este preprocesamiento se dá cierta robustez al método propuesto a variaciones de escala y orientación de los objetos.

El preprocesamiento realizado consta de tres etapas: sustracción del fondo, segmentación del objeto y escalamiento del objeto segmentado. A continuación se describen las etapas del preprocesamiento:

1. **Sustracción del fondo:** La sustracción del fondo consiste en separar a los objetos del fondo del ambiente. Se realiza restando a la imagen actual que puede o no contener objetos de interés, una imagen previa del fondo del ambiente sin objetos. Cada robot tiene *a priori* una imagen previa del fondo del ambiente capturada con su propia cámara de video. Como resultado se obtienen distintas regiones que reflejan las diferencias entre ambas imágenes. En esta etapa se supone que se tiene un fondo uniforme y estático.
2. **Segmentación del objeto:** La segmentación del objeto consiste en identificar la región en la que se encuentra el objeto de interés. En esta etapa se eliminan aquellas regiones obtenidas en la etapa de sustracción del fondo que no corresponden al objeto. Para realizar lo antes mencionado es necesario aplicar operaciones morfológicas de *closing* y *erosion* con un elemento estructurante de 3×3 píxeles, las cuales permiten unir regiones cercanas y eliminar regiones pequeñas¹. Al final del proceso de segmentación se obtienen las dimensiones del rectángulo más chico que

¹**Erosión:** Agranda huecos existentes en el objeto, reduce los bordes, elimina “islas” y remueve “penínsulas” angostas que puedan existir en el borde. **Dilatación:** Permite rellenar huecos en los objetos y expandir sus bordes, con lo cual se rellenan regiones angostas. **Closing:** Se forma por la combinación de las operaciones morfológicas de *dilatación* y *erosión* (Awcock y Thomas (1995)). El principal efecto de la operación *closing* es cerrar huecos entre regiones y compactarlas.

contiene a la región segmentada, $p_1(x_1, y_1)$ y $p_2(x_2, y_2)$, que representan respectivamente la esquina superior izquierda y la esquina inferior derecha del rectángulo. Si las dimensiones del rectángulo pasan el valor de un tamaño mínimo, entonces se considera que la región actual corresponde efectivamente a la segmentación de un objeto de interés completo; en otro caso, el objeto no es considerado pues se supone que la imagen contiene únicamente una porción del mismo.

3. **Escalamiento del objeto segmentado:** Esta etapa consiste en escalar el objeto segmentado del punto anterior a un tamaño fijo, por ejemplo, de 200×100 píxeles. En primer lugar debe recortarse de la imagen original la región que contiene al objeto segmentado empleando los puntos del rectángulo $(p_1(x_1, y_1), p_2(x_2, y_2))$ más chico que lo contiene. Posteriormente, se escala la imagen recortada al tamaño antes mencionado independientemente de si la región correspondiente al objeto segmentado es mayor o menor a las dimensiones de 200×100 píxeles. La idea de escalar a los objetos a un tamaño fijo permite obtener características globales PCA en las que las variaciones en posición o escala de los objetos no sean relevantes.

4.5.2. Extracción de características y entrenamiento individual

En la etapa de entrenamiento un robot es capaz de observar a un único objeto por vez con su cámara de video mientras avanza a lo largo de una trayectoria predefinida, ya que ésta es una restricción del sistema. Es el robot el que determina que se encuentra observando a un mismo objeto mientras va avanzando y capturando imágenes de él. Desde el momento en el que el robot detecta un cambio entre las imágenes capturadas con su cámara de video y la imagen almacenada del fondo ambiente, se dice que el robot se encuentra observando a un objeto en particular, y deja de verlo cuando ya no se detectan cambios significativos entre las imágenes capturadas por el robot y la imagen de fondo almacenada.

A la secuencia de imágenes o vistas capturadas por un robot correspondientes a un mismo objeto se les conoce como bloque de imágenes, y se tienen tantos bloques de

imágenes como objetos distintos observados por el robot.

Por cada bloque de imágenes correspondiente a un objeto en particular se obtienen las características que representan al objeto en cuestión. Dichas características se extraen de cada una de las imágenes del bloque de imágenes en las que se detecta un objeto (ver sección 4.5.1), y se van agrupando por objetos, para posteriormente realizar el entrenamiento individual.

A continuación se describe el proceso de extracción de características globales PCA y locales SIFT por cada bloque de imágenes, y el entrenamiento individual empleando dichas características.

4.5.2.1. Entrenamiento PCA

En este trabajo se propone emplear la silueta promedio de cada objeto de entrenamiento para realizar el entrenamiento PCA, debido a que la silueta promedio proporciona una mejor representación de la forma de los objetos que la silueta de una sola imagen, ya que no se adquiere de forma puntual, y permite reducir los efectos de los errores en la segmentación. Además, la silueta promedio también permite representar y reducir las variaciones entre las diferentes vistas del mismo objeto capturadas por un robot.

Las siluetas promedio se obtienen como se indica en la sección 2.5.2 a partir de los objetos detectados en la sección 4.5.1 de cada imagen del bloque de imágenes de un mismo objeto. Por lo tanto, las siluetas promedio que se obtienen de los distintos objetos, se encuentran centradas y escaladas a un tamaño fijo, con lo cual se obtiene cierta robustez a variaciones de escala y orientación de los objetos en las imágenes originales.

Una vez que se tienen las siluetas promedio de los objetos de entrenamiento se puede realizar el entrenamiento PCA, como se explica en la sección 2.6.1, en donde se reduce la dimensionalidad de las siluetas promedio al ser proyectadas al nuevo eigenespacio PCA calculado durante el entrenamiento. Por lo tanto, cada silueta promedio, se representa por un vector de dimensión $nEigens$, en donde $nEigens$ corresponde al número de eigenvectores empleados para representar a los distintos objetos. A estos vectores se les conoce como conceptos individuales PCA de los objetos de entrenamiento.

En el apéndice A se proporcionan ejemplos de los conceptos individuales PCA referentes de esta sección.

4.5.2.2. Entrenamiento SIFT

La fase de entrenamiento SIFT consiste en extraer las características locales SIFT de los bloques de imágenes que representan a cada objeto de entrenamiento.

El proceso de obtención del conjunto de características SIFT para un objeto de entrenamiento consiste en obtener de cada una de las imágenes del bloque de imágenes correspondiente al objeto en cuestión, el conjunto de características SIFT como se describe en la sección 2.5.1. Por lo tanto, por cada imagen de entrenamiento de un mismo objeto se van extrayendo las características locales SIFT y se van agrupando en un conjunto que al final contendrá todas las características SIFT distintas extraídas del bloque de imágenes del objeto dado. En la figura 4.7 se muestran los puntos SIFT obtenidos para el bloque de imágenes correspondiente al objeto florero y su respectivo conjunto final de SIFT resultantes.

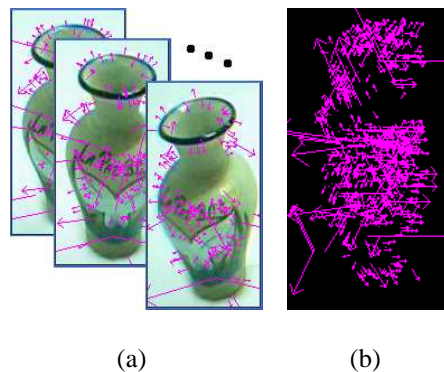


Figura 4.7: a) Características locales SIFT extraídas del bloque de imágenes del objeto florero y b) conjunto de SIFT resultante o concepto individual SIFT del objeto florero.

Al final se obtiene un conjunto de características SIFT por cada objeto de entrenamiento, y a estos conjuntos de características se les conoce como representaciones individuales SIFT o conceptos individuales SIFT para los objetos de entrenamiento.

En el apéndice A se proporcionan ejemplos de los conceptos individuales SIFT presentados en esta sección.

4.6. Comunicación

Para que un sistema multi-robot exhiba comportamientos cooperativos, los miembros del sistema deben ser capaces de comunicarse entre sí. En el presente trabajo la comunicación entre los miembros del sistema multi-robot se realiza de forma directa a través de un canal de comunicación explícito.

Una vez que cada robot ha aprendido de forma individual un cierto conjunto de conceptos o inclusive un solo concepto individual, los robots deben compartir sus conceptos entre los demás miembros del sistema multi-robot a través de una conexión directa empleando una red inalámbrica *WiFi*. En este punto cada robot conoce de antemano la dirección IP de los demás robots y viceversa, por lo que mediante hilos, cada robot se mantiene “escuchando” en los puertos correspondientes hasta que los robots le envíen información. Los robots envían las siluetas promedio y los conceptos individuales SIFT de los objetos, una vez que han terminado de realizar el entrenamiento individual.

El módulo de comunicación permite a los robots realizar los dos tipos de aprendizaje cooperativo implementados en esta tesis, el aprendizaje cooperativo fuera de línea y el aprendizaje cooperativo en línea. En el primero la compartición de conceptos se realiza una vez que el robot ha realizado el entrenamiento individual para aprender conceptos individuales de todos los objetos de entrenamiento observados por él mismo. En el segundo, el aprendizaje cooperativo en línea, la compartición de conceptos individuales se realiza después de que en el entrenamiento individual se ha aprendido un concepto por cada objeto de entrenamiento.

4.7. Aprendizaje cooperativo de conceptos

El aprendizaje cooperativo de conceptos permite obtener un concepto colectivo a partir de los conceptos individuales aprendidos por los miembros del sistema multi-robot. Este tipo de aprendizaje permite que cada miembro del sistema enriquezca sus conceptos individuales combinando la información adquirida por otros robots que observaron al mismo objeto, y adquiriendo nuevas representaciones de objetos no vistos por el robot. Esto implica principalmente el incremento del número de objetos conocidos por los robots, además, de que se espera tener evidencias distintas que ayuden a formar conceptos colectivos más robustos y útiles para los propios robots.

Para obtener un concepto colectivo cada robot realiza un análisis de los conceptos individuales propios y los compartidos, tomando en cuenta los conceptos colectivos conocidos hasta ese momento por el robot. El análisis permite detectar tres tipos de información: coincidente, complementaria y confusa. Dependiendo del tipo de información detectada durante el análisis será el tipo de fusión de conceptos a realizar por el robot.

El análisis y fusión de conceptos realizado por un robot es independiente del análisis y fusión de conceptos realizado por el otro robot. A continuación se describe el análisis realizado, los tres tipos de información que pueden ser detectados, y el tipo de fusión correspondiente realizada en cada caso.

4.7.1. Pre-análisis de conceptos individuales

En general, a lo largo del documento, los conceptos aprendidos por un robot se definen como se indica en la expresión 4.1.

$$C_k^i = \{PCA_k^i, SIFT_k^i\} \quad (4.1)$$

donde C_k^i es el concepto k aprendido por el robot i , PCA_k^i es eigenvector o la proyección que representa a la silueta promedio Sil_k^i dentro del eigenespacio PCA del robot i , y $SIFT_k^i$ es el conjunto de características SIFT que forman al concepto k .

Para realizar el pre-análisis de conceptos individuales, los robots emplean la definición

de concepto individual que se indica en la expresión 4.2.

$$C_k^i = \{Sil_k^i, SIFT_k^i\} \quad (4.2)$$

donde Sil_k^i es la silueta promedio y $SIFT_k^i$ es el conjunto de características SIFT que forman al concepto k .

El pre-análisis de los conceptos individuales consiste en obtener vectores de probabilidades PCA y SIFT. Los vectores de probabilidad permiten a los robots comparar sus conceptos propios con los conceptos compartidos por el otro robot del sistema multi-robot. La dimensión de cada vector de probabilidades es de $numObjs$, donde $numObjs$ es el número de objetos conocidos por el robot actual. Los vectores de probabilidades PCA y SIFT se denotan como v_P y v_S , respectivamente. A continuación describimos el proceso para obtener los vectores de probabilidades PCA y SIFT.

El vector de probabilidades PCA calculado por el robot i , v_P^i , indica la probabilidad de que un concepto k compartido por el robot j , C_k^j , sea similar a los conceptos conocidos por el robot i , $C_1^i, \dots, C_{numObjs^i}^i$, dadas las características globales. $numObjs^i$ es el número de conceptos de objetos conocidos por el robot i . El proceso para obtener el vector de probabilidades v_P^i del robot i dado un concepto C_k^j compartido por el robot j se describe a continuación:

1. Se crea un conjunto temporal de siluetas promedio de entrenamiento. Dicho conjunto se forma agregando a las siluetas promedio de los conceptos conocidos por el robot i o robot actual, $Sil_1^i, \dots, Sil_{numObjs^i}^i$, la silueta promedio del concepto compartido Sil_k^j .
2. Se aplica el entrenamiento PCA de la sección 2.6.1 empleando el conjunto temporal de siluetas promedio. Se obtienen las proyecciones de las siluetas promedio conocidas por el robot i en una matriz de proyecciones, $matProys$. Además, se obtiene la proyección de la silueta promedio Sil_k^j en un vector, $vectProys$. Las proyecciones de obtienen como se indica en la sección 2.6.1 punto 6.

3. Se calcula la distancia Euclidiana (dE) entre cada vector de la matriz $matProys$ y el vector $vectProys$ como se muestra en la expresión 4.3.

$$dE_l^i = \sqrt{\sum_{r=1}^{nEigens} (matProys_{(l,r)} - vectProys_{(1,r)})^2} \quad (4.3)$$

donde $nEigens$ es el número de eigenvectores utilizado durante el entrenamiento PCA ($nEigens = numObjs - 1$), y l es el índice del vector de distancia dE^i calculado por el robot i cuyo valor máximo es $numObjs^i$.

4. Se divide cada elemento del vector de distancia dE^i entre un valor máximo de distancia, $umbralMax^2$, para obtener un vector de pseudo-probabilidades v_P^i como se muestra en la ecuación 4.4.

$$v_{P_i}^i = 1 - \frac{dE_l^i}{umbralMax} \quad (4.4)$$

Si dE_l^i es mayor que el valor del umbral máximo $umbralMax$, entonces el valor de la probabilidad se dejará como $v_{P_i}^i = 0.01$, lo que indica que la proyección del objeto j y la del objeto i son completamente distintas entre sí.

En este caso fue necesario realizar el proceso de los puntos 1 y 2 antes mencionados debido a que si únicamente proyectamos las siluetas promedio de los objetos aprendidos por el robot j al eigenspacio del robot i , $eigensRi$, éste proyectará dichas siluetas aproximando su forma a alguna de las siluetas de los objetos conocidos por el robot i . Para casos en los que ambos robots observaron al mismo objeto, la proyección reflejará la similitud entre los objetos aprendidos por ambos robots. Sin embargo, para casos en los que el robot i desconoce a algún objeto aprendido por el robot j , entonces dicho objeto se proyectará como una aproximación a alguno de los objetos conocidos por el robot i , lo

² $umbralMax$ es un valor máximo de distancia determinado experimentalmente. Dicho valor se calcula a partir de una serie de experimentos en los que se obtienen las distancias mínimas y máximas entre la proyección de un objeto de prueba y las proyecciones de los objetos de entrenamiento. Dicho valor permite indicar si dos proyecciones son distintas, es decir, si la distancia entre ambas se aproxima al valor $umbralMax$.

cual no refleja a ciencia cierta si en realidad el robot i conoce o no el objeto compartido. Por lo anterior fue necesario que por cada objeto aprendido y compartido por el robot j , se re-entrenaran los PCA como se indica en los puntos 1 y 2 antes mencionados. En la parte experimental de la presente tesis, se hablará de estos aspectos de la clasificación para el reconocimiento de objetos.

El valor del vector de pseudo-probabilidades SIFT en la posición $v_{S_l}^i$, se obtiene calculando el número de SIFT coincidentes, $n_{coin[l,k]}$, entre el concepto individual $SIFT_l^i$ aprendido por el robot i , y el concepto individual $SIFT_k^j$ compartido por el robot j . Si el número de coincidencias $n_{coin[l,k]}$ es mayor que un valor promedio de coincidencias determinado experimentalmente, $promCoin^3$, entonces la probabilidad será $v_{S_l}^i = 1.0$, lo que significa que ambos conceptos contienen en su mayoría características locales SIFT similares. En otro caso, la probabilidad se obtendrá empleando la ecuación 4.5.

$$v_{S_l}^i = \frac{n_{coin[l,k]}}{promCoin} \quad (4.5)$$

A lo largo del documento se hará referencia a los vectores de probabilidades obtenidos durante el pre-análisis de cada concepto compartido C_k^j , es decir, $C_1^j, \dots, C_{numObj_s^j}^j$, respecto a todos los objetos conocidos hasta ese momento por el robot i , $C_1^i, \dots, C_{numObj_s^i}^i$, como $v_{P_{(k,1:numObj_s^i)}}^i$ y $v_{S_{(k,1:numObj_s^i)}}^i$, lo que indica que nos referimos a los vectores que contienen las relaciones de forma y de características SIFT entre el concepto k y todos los objetos conocidos por el robot i ($numObj_s^i$).

4.7.2. Información coincidente

La información coincidente ocurre cuando dos o más robots obtienen vistas similares de un mismo objeto durante el entrenamiento individual. En general, los objetos que generan información coincidente son simétricos verticalmente y además son recurrentes

³*promCoin* es el número promedio de coincidencias entre dos conjuntos de puntos SIFT que permite indicar que ambos conjuntos corresponden al mismo objeto. Este valor se obtiene a partir de una serie de experimentos en los que se calcula el promedio de SIFT coincidentes entre objetos de prueba y los objetos de entrenamiento del mismo tipo con diferentes distancias y orientaciones.

por sus características locales, es decir, independientemente del punto de vista en el que los robots los vean durante el entrenamiento individual, sus formas y texturas serán similares entre sí. Sin embargo, aún cuando es poco probable, los demás tipos de objetos también pueden producir éste tipo de información, siempre y cuando, los robots los observen durante el entrenamiento individual desde puntos de vista similares. En la figura 4.8 se ilustran las trayectorias seguidas por dos robots durante el entrenamiento individual de un objeto simétrico y recurrente.




Figura 4.8: Trayectorias seguidas por los robots 1 y 2 durante el entrenamiento individual del objeto botella. Por la naturaleza del objeto, es decir, porque es simétrico verticalmente y recurrente, los conceptos aprendidos por los dos robots son coincidentes.

Para que el robot i sea capaz de determinar la existencia de información coincidente entre su concepto colectivo C_i^i y el concepto compartido por el robot j , C_k^j , los valores de los vectores de probabilidades PCA y SIFT en la posición $v_{P(k,l)}^i$ y $v_{S(k,l)}^i$ deben poseer los valores de probabilidad más altos de todo el vector de probabilidades correspondiente, $v_{P_k}^i$ y $v_{S_k}^i$, respectivamente. Además, los valores de las probabilidades $v_{P(k,l)}^i$ y $v_{S(k,l)}^i$ también deben ser mayores o iguales a un umbral, $umbralProba$, determinado experimentalmente⁴. Si lo anterior se cumple, se considera que el concepto C_l^i y el concepto C_k^j

⁴ $umbralProba$ se obtiene a partir de una serie de experimentos en los que se observan las probabilidades obtenidas tanto PCA como SIFT durante el análisis y fusión de conceptos. Este valor es elegido a partir del conjunto de experimentos de tal forma que permita detectar las coincidencias entre objetos similares y discriminar entre objetos distintos para no hacer coincidentes a un par de conceptos correspondientes a objetos distintos. En el capítulo de experimentos y resultados se indicará el valor calculado para esta variable.

son coincidentes tanto en forma como en características locales SIFT.

En la expresión 4.6 se muestran las condiciones que el robot i necesita detectar para determinar la existencia de información coincidente a partir de los vectores de probabilidades PCA y SIFT calculados por el robot i . En la expresión 4.6 el valor de 1 indica que un concepto C_l^i aprendido por el robot i , es coincidente con un concepto C_k^j aprendido y compartido por el robot j .

$$ObjCoin_{(k,l)} = \begin{cases} 1 & \text{Si } v_{P_{(k,l)}}^i \geq umbralProba \text{ y } v_{S_{(k,l)}}^i \geq umbralProba \\ 0 & \text{En otro caso} \end{cases} \quad (4.6)$$

Una vez determinada la coincidencia entre los conceptos C_l^i y C_k^j , la fusión de estos conceptos se realiza en dos partes como se muestra a continuación:

1. **Fusión PCA:** La fusión empleando las características PCA consiste básicamente en promediar las siluetas promedio correspondientes a los conceptos C_l^i y C_k^j que resultaron ser coincidentes, es decir, Sil_l^i y Sil_k^j , respectivamente. Posteriormente, se re-entrenan los PCAs con las siluetas promedio de los conceptos colectivos conocidos hasta ese momento por el robot i , $Sil_1^i, \dots, Sil_{numObj^i}^i$, sustituyendo la silueta del concepto C_l^i por la silueta promedio actualizada, la cual contiene también información del objeto aprendido por el robot j .

En este punto empleamos el promedio de las siluetas de ambos conceptos para fusionar datos coincidentes debido a que desconocemos con cuál de las siluetas promedio tenemos una mejor representación de la forma del objeto. Es importante mencionar que aunque en algunos casos el promedio de las siluetas l y k puede reducir la calidad de la silueta que representa al objeto, en otros un robot mejora su representación del mismo.

2. **Fusión SIFT:** La fusión empleando las características SIFT consiste en agregar los puntos SIFT no coincidentes o complementarios que representan al concepto C_k^j aprendido por el robot j , al conjunto de SIFT que representan al concepto colectivo

C_l^i conocido por el robot i , $SIFT_l^i$. Además, por cada par de SIFT coincidentes, se obtiene el promedio de los SIFT, es decir, se promedia tanto la posición en la que se encuentran los SIFT como los descriptores del punto.

Al haber información coincidente entre los conceptos C_l^i y C_k^j , sus conjuntos de SIFT correspondientes tienen gran cantidad de puntos coincidentes, es decir, que se parecen en ubicación y en orientación. Sin embargo, en ambos conjuntos también existen otros puntos, los puntos SIFT que son distintos o complementarios, que se obtienen debido a las distintas vistas del mismo objeto observadas por los dos robots. Por lo tanto, al agregar los puntos SIFT complementarios del concepto C_k^j al conjunto de SIFT del concepto C_l^i , se enriquece la representación del concepto colectivo C_l^i en el robot i , pues la información que se está adquiriendo era desconocida a pesar de haberse establecido la coincidencia.

4.7.3. Información complementaria

La información complementaria ocurre cuando tanto por la forma de los objetos como por sus características locales, al menos un objeto de los aprendidos por el robot que compartió sus conceptos individuales (robot j), es distinto a todos los objetos aprendidos por el robot actual o robot en el que se realiza el análisis (robot i).

En la figura 4.9 se ilustran las trayectorias seguidas por dos robots durante el entrenamiento. En este caso cada robot aprende conceptos de un objeto distinto, por lo cual durante el análisis de los conceptos individuales se determinará la existencia de información complementaria.

Haciendo uso de la expresión 4.7 y empleando los vectores de probabilidades PCA, v_P^i , y SIFT, v_S^i , antes definidos, el robot i es capaz de determinar la existencia de información complementaria entre sus conceptos actuales, $C_1^i, \dots, C_{numObj^i}^i$, y el concepto individual C_k^j compartido por el robot j .



Figura 4.9: Trayectorias seguidas por los robots 1 y 2 durante su entrenamiento individual. El robot 1 aprende el objeto *pelota* y el robot 2 aprende el objeto *botella*.

$$ObjComple_k = \begin{cases} 1 & \text{Si } v_{P(k,l)}^i < umbralProba \text{ y } v_{S(k,l)}^i < umbralProba \\ & \forall l, \text{ con } 1 \leq l \leq numObj_s^i \\ 0 & \text{En otro caso} \end{cases} \quad (4.7)$$

Donde l y k indican los conceptos C_l^i y C_k^j aprendidos por los robots i y j respectivamente, $numObj_s^i$ es el número de objetos conocidos por el robot i y $umbralProba$ es un umbral de probabilidades que se determinará experimentalmente. Por lo tanto, cuando $ObjComple_k = 1$ indica que el concepto C_k^j es complementario a todos los conceptos colectivos conocidos por el robot i , y por lo tanto se agregará como un nuevo concepto al conjunto de conceptos colectivos conocidos por el robot i .

Para realizar la fusión del concepto complementario C_k^j a los conceptos colectivos o actualmente conocidos por el robot i , es necesario realizar los dos pasos siguientes:

1. **Fusión PCA:** La fusión empleando las características globales PCA consiste en agregar al conjunto de siluetas promedio de los conceptos conocidos por el robot i , $Sil_1^i, \dots, Sil_{numObj_s^i}^i$, la silueta promedio del concepto C_k^j , Sil_k^j . Posteriormente, el robot i re-entrena empleando PCA y el conjunto de siluetas promedio actualizado. Finalmente, proyecta todas las siluetas promedio conocidas al nuevo eigenspacio, obteniendo con esto los eigenvectores que representan a todas las siluetas promedio de los objetos conocidos por el robot.

2. **Fusión SIFT:** La fusión empleando las características SIFT consiste en agregar al conjunto de características SIFT de los objetos actualmente conocidos por el robot i , $SIFT_1^i, \dots, SIFT_{numObj_s^i}^i$, un nuevo conjunto, el cual contiene el conjunto de características SIFT del objeto C_k^j , es decir, $SIFT_k^j$.

4.7.4. Información confusa

En la información confusa pueden presentarse dos casos entre los conceptos C_i^i y C_k^j aprendidos por los robots i y j respectivamente:

1. **Objetos confusos del tipo 1: Diferente forma, características SIFT similares.**

Ocurre cuando el concepto C_k^j es complementario por su forma, Sil_k^j , a los conceptos conocidos por el robot i , es decir, no es reconocido como un objeto conocido. Sin embargo, por sus características SIFT, $SIFT_k^j$, el concepto se parece o es coincidente con alguno de los objetos aprendidos por el robot i . Cuando se detecta este tipo de información, el robot i considera al concepto C_k^j como complementario y lo trata como tal al realizar la fusión de los conceptos.

2. **Objetos confusos del tipo 2: Misma forma, características SIFT diferentes.**

Ocurre cuando el concepto C_k^j es coincidente por su forma, Sil_k^j , con alguno de los conceptos aprendidos por el robot i , pero por sus características locales SIFT, $SIFT_k^j$, se detecta que el concepto es complementario a los objetos conocidos por el robot i . En este tipo de información confusa pueden presentarse los dos subcasos siguientes:

- a) **Objetos distintos:** Los objetos distintos son aquellos que a pesar de tener formas similares, tienen características SIFT que permiten diferenciarlos.
- b) **Mismo objeto:** Los objetos tienen la misma forma pero a pesar de que sus características SIFT indican que se trata de objetos distintos, en realidad se trata del mismo objeto visto desde puntos de vista diferentes.

Haciendo uso de la expresión 4.8 y empleando los vectores de probabilidades PCA (v_P^i) y SIFT (v_S^i) definidos en la sección de pre-análisis de conceptos individuales (cf. 4.7.1), el robot i es capaz de determinar la existencia de información confusa entre los conceptos C_l^i y C_k^j .

$$ObjConfu_{(k,l)} = \begin{cases} 1 & \text{Si } v_{S_{(k,l)}}^i \geq umbralProba \text{ y } v_{P_{(k,l)}}^i < umbralProba(Tipo1) \\ 1 & \text{Si } v_{P_{(k,l)}}^i \geq umbralProba \text{ y } v_{S_{(k,l)}}^i < umbralProba(Tipo2) \\ 0 & \text{En otro caso} \end{cases} \quad (4.8)$$

Independientemente del tipo de confusión, ambas son resueltas como si se tratara de un nuevo objeto. Dado que el robot i no tiene forma de determinar, empleando únicamente la información con la que cuenta, que se trata del mismo objeto o que es en realidad un nuevo objeto. Por lo tanto, la confusión se resuelve empleando la fusión de conceptos del caso de información complementaria descrita en la sección 4.7.3.

Para el caso de la confusión del tipo 2, es el supervisor el que detecta que se trata del mismo objeto pero visto por los robots desde puntos de vista distintos. Para que los robots sean capaces de resolver este tipo de confusión de forma automática, es necesario incrementar la evidencia conocida por los robots, es decir, es necesario al menos un nuevo concepto de una tercera vista del objeto, el cuál contenga información parcial de las vistas de los dos conceptos que resultaron ser confusos. Si un robot es capaz de obtener esta tercer vista del objeto, la confusión puede resolverse de la misma forma como se indica en la sección de información coincidente (cf. sección 4.7.2), fusionando en un solo concepto a los tres conceptos anteriormente mencionados, realizando la fusión por pares de conceptos. En la sección 5.3.3.2 se proporciona un ejemplo de esta situación. En dicho ejemplo se supone que un robot es capaz de obtener automáticamente la tercer vista del objeto.

4.8. Reconocimiento de objetos

El reconocimiento de objetos se basa en las probabilidades PCA, SIFT y la fusión Bayesiana de las probabilidades PCA y SIFT, que indican la probabilidad de que un nuevo objeto se clasifique con alguno de los objetos de entrenamiento.

A continuación presentamos el reconocimiento de objetos empleando las características PCA y SIFT (provenientes o de los conceptos individuales o de los conceptos colectivos). Posteriormente, presentamos la fusión Bayesiana de las probabilidades PCA y SIFT para el reconocimiento de objetos.

4.8.1. Reconocimiento empleando características PCA

El reconocimiento de objetos empleando las características globales PCA consiste en obtener las probabilidades de clasificación PCA, $probaPCA$, de una imagen de prueba dadas las proyecciones PCA de los objetos de entrenamiento.

En el Algoritmo 4.1 Reconocimiento de objetos empleando PCA se realiza el cálculo de las probabilidades PCA. Este algoritmo recibe como parámetro de entrada la imagen de prueba, $imgTest$. Como variables globales recibe el número de objetos de entrenamiento, n ; el número de eigenvectores empleados, $nEigens$; la matriz de proyecciones de los objetos de entrenamiento, $matProysTrain$; y un valor de distancia máximo determinado experimentalmente, $umbralMax$, que permite establecer cuándo las proyecciones de dos objetos son completamente distintas, es decir, si la distancia entre las proyecciones de dos objetos es mayor o igual a este valor de umbral máximo, se considera que los objetos son completamente distintos entre sí.

A continuación describimos el Algoritmo 4.1 de reconocimiento de objetos empleando las características PCA de los conceptos individuales o de los colectivos.

En primer lugar se detecta si la imagen de prueba contiene a un objeto empleando el esquema descrito en la sección 4.5.1. Si fue el caso, se obtiene la silueta, $imgSilueta$, del objeto contenido en la imagen de prueba segmentada. Posteriormente, se proyecta dicha silueta al eigespacio del robot actual, $eigens$, y se obtiene un vector que contiene la

proyección de la silueta del objeto de prueba, $vectProys$. Para obtener la probabilidad de que la proyección de la imagen de prueba pertenezca a la clase de alguno de los objetos de entrenamiento, se obtienen en el vector $dist$ las distancias Euclidianas entre las proyecciones de los objetos de entrenamiento contenidas en la matriz $matProysTrain$ y la proyección de la silueta de pruebas, $vectProys$. Si la distancia de la proyección de la imagen de pruebas dado el objeto de entrenamiento l es mayor que el valor de distancia máximo, es decir, si $dist[l] > umbralMax$, entonces la probabilidad PCA será $probaPCA[l] = 0.01$, lo cual indica que el objeto de prueba es completamente distinto al objeto de entrenamiento l . En otro caso, la probabilidad PCA se calcula de la siguiente manera, $probaPCA[l] = 1 - \frac{dist[l]}{umbralMax}$.

Algoritmo 4.1. Reconocimiento de objetos empleando PCA

Datos globales: Número de objetos de entrenamiento, n ; número de eigenvectores empleados, $nEigens$; matriz de proyecciones de los objetos de entrenamiento $matProysTrain$ de dimensiones $n \times nEigens$; valor de distancia máxima determinado experimentalmente $umbralMax$.

Datos locales: Imagen en escala de grises $imgSilueta$ de dimensiones 200×100 píxeles; vector de proyecciones de la imagen de prueba, $vectProys$; vector de distancias, $dist$; vector que contiene las probabilidades calculadas, $probaPCA$; valor booleano, $objDetectado$; valor entero, ind ; valor flotante, $suma$.

Datos de entrada: Imagen de prueba, $imgTest$.

Datos de salida: Clase del objeto de pruebas, Cl .

1. Detectar objeto en la imagen de prueba $imgTest$. Si hay un objeto regresar $objDetectado = 1$, en otro caso, $objDetectado = 0$.

2. **Si** $objDetectado = 1$ **entonces**

2.1 Obtener la silueta $imgSilueta$ de la imagen de prueba segmentada.

2.2 Proyectar la silueta $imgSilueta$ al eigenespacio empleando los primeros $nEigens$ eigenvectores, lo que genera como resultado un vector de proyecciones $vectProys$ de dimensión $nEigens$.

2.3 **Para** $l \leftarrow 1$ **hasta** n

2.3.1 Calcular la distancia Euclidiana de la proyección $vectProys$ a la proyección del objeto de entrenamiento l . El proceso se muestra a continuación:

$suma \leftarrow 0$

Para $r \leftarrow 1$ **hasta** $nEigens$

$suma \leftarrow suma + (matProysTrain[l][r] - vectProys[r])^2$

$dist[l] \leftarrow \sqrt{suma}$

Continúa en la siguiente página...

Algoritmo 4.1. Reconocimiento de objetos empleando PCA (Continuación)

2.3.2 Calcular la probabilidad de que la proyección de la imagen *imgSilueta* pertenezca a la clase del objeto *l* de entrenamiento. Para lo cual se realiza lo siguiente:

Si $dist[l] > umbralMax$ **entonces** las proyecciones son completamente distintas:

$$probaPCA[l] \leftarrow 0.01$$

En otro caso

$$probaPCA[l] \leftarrow 1 - \frac{dist[l]}{umbralMax}$$

Fin si

2.4 Obtener el índice *ind* con mayor probabilidad del vector *probaPCA*, y determinar la clase de la imagen de prueba como: $Cl \leftarrow ind$.

2.5 Regresar *Cl*.

Fin si

Fin del algoritmo

4.8.2. Reconocimiento empleando características SIFT

El reconocimiento de objetos empleando las características locales SIFT de los objetos consiste en obtener las probabilidades de clasificación SIFT, *probaSIFT*, del conjunto de SIFT de una imagen de prueba, *ConjSift*, dados los conjuntos de SIFT de los objetos de entrenamiento, *ConjSiftTrain*.

En el Algoritmo 4.2 Reconocimiento de objetos empleando características SIFT, se realiza el cálculo de las probabilidades SIFT. Este algoritmo recibe como parámetro de entrada una imagen de pruebas. Como variables globales, el algoritmo recibe el número de objetos de entrenamiento, *n*; el conjunto de características SIFT de los objetos de entrenamiento, *ConjSiftTrain*; y un valor que indica el promedio máximo de coincidencias con el cual determinamos que dos conjuntos de SIFT contienen la misma información, *promCoin*. A continuación describimos el funcionamiento del Algoritmo

4.2.

Por cada concepto l (que puede provenir de los conceptos individuales o colectivos del robot actual) se calcula el número de SIFT coincidentes entre el conjunto de SIFT de la imagen de prueba y el conjunto de SIFT de los conceptos de entrenamiento, y se almacena el número de coincidencias en el vector de coincidencias en la posición correspondiente, $vect_{coin}[l]$.

Para determinar las coincidencias entre dos conjuntos de SIFT, se utiliza la función de David G. Lowe de **coincidencias** (Lowe (2004)). Emplea *knn* y *BBF* (*Best Bin First*) para determinar que dos puntos SIFT son coincidentes. A continuación presentamos una breve descripción del funcionamiento de la función de **coincidencias**:

- Construir un árbol *kd-tree* empleando los $n1$ puntos SIFT correspondientes al concepto que representa al objeto de entrenamiento l .
- Por cada punto SIFT k del conjunto de SIFT del objeto de pruebas, que tiene $n2$ SIFT en total, buscar en el árbol *kd-tree* a sus dos vecinos más cercanos.
- Obtener las distancias Euclidianas entre los descriptores del punto k y los descriptores de los 2 vecinos más cercanos antes detectados, $d0$ y $d1$.
- Considerar que el punto SIFT k coincide con su primer vecino más cercano, siempre y cuando la distancia Euclidiana del vecino más cercano, $d0$, sea menor que la distancia del segundo vecino más cercano multiplicado por un factor constante, $d1 \times umbral$. Por lo tanto si $d0 < d1 \times umbral$ entonces se considera que el punto SIFT vecino $d0$ del punto k es coincidente, por lo cual se incrementa el número de SIFT coincidentes en 1.

Si el número de SIFT coincidentes con el objeto l , es decir, $vect_{coin}[l]$, es mayor o igual al promedio de coincidencias $promCoin$ (determinado experimentalmente), se considera que la probabilidad SIFT de que el objeto de pruebas se parezca a la clase del objeto de entrenamiento l es $probaSIFT[l] = 1.0$. Lo cual implica que el objeto de pruebas se

clasifica con el objeto l . En otro caso, se obtiene la probabilidad SIFT dependiendo del número de SIFT coincidentes, es decir, $probaSIFT[l] = \frac{vect_{coin}[l]}{promCoin}$.

Algoritmo 4.2. Reconocimiento de objetos empleando características SIFT (Scale Invariant Feature Transform)

Datos globales: Número de objetos de entrenamiento, n ; vector de apuntadores a los conjuntos de SIFT de los objetos de entrenamiento, $ConjSiftTrain$; promedio de coincidencias determinado experimentalmente, $promCoin$.

Datos locales: Imagen a color del objeto segmentado $imgSegmentada$ de dimensiones 200×100 píxeles; apuntador al conjunto de SIFT de la imagen de prueba, $ConjSift$; vector de enteros que contiene el número de coincidencias, $vect_{coin}$; vector que contiene las probabilidades, $probaSIFT$; índice que apunta a la posición con mayor probabilidad del vector $probaSIFT$, ind .

Datos de entrada: Imagen de prueba, $imgTest$.

Datos de salida: Clase del objeto de pruebas, Cl .

Este algoritmo emplea la función *Coincidencias* de David G. Lowe que permite calcular el número de SIFT en común entre dos conjuntos de SIFT. Emplea *knn* y *BBF (Best Bin First)* para determinar que dos puntos SIFT son coincidentes.

1. Detectar objeto y segmentarlo de la imagen de prueba $imgTest$ y dejarlo en la imagen $imgSegmentada$. En caso de que la imagen de prueba no contenga a ningún objeto, es decir $imgSegmentada = 0$, terminar.
2. **Si** $imgSegmentada \neq 0$ **entonces**
 - 2.1 Extraer de la imagen $imgSegmentada$ su conjunto de características SIFT, $ConjSift$.
 - 2.2 **Para** $l \leftarrow 1$ **hasta** n
 - 2.2.1 Obtener el número de coincidencias SIFT entre el conjunto de SIFT del objeto de entrenamiento l con el conjunto de SIFT de la $imgSegmentada$:
 $vect_{coin}[l] \leftarrow Coincidencias(ConjSiftTrain[l], ConjSift)$.

Continúa en la siguiente página...

Algoritmo 4.2. Reconocimiento de objetos empleando características SIFT (Continuación)

2.2.2 Calcular la probabilidad de que la imagen $imgSegmentada$ pertenezca a la clase de alguno de los objetos de entrenamiento. Para lo cual se realiza lo siguiente:

Si $vect_{coin[l]} > promCoin$ **entonces**

$$probaSIFT[l] \leftarrow 1$$

En otro caso

$$probaSIFT[l] \leftarrow \frac{vect_{coin[l]}}{promCoin} + 0,01$$

Fin si

2.3 Obtener el índice ind del valor con mayor probabilidad del vector $probaSIFT$, y determinar la clase de la imagen de prueba como: $Cl \leftarrow ind$.

2.4 Regresar Cl .

Fin si

Fin del algoritmo

4.8.3. Reconocimiento empleando la fusión Bayesiana

El reconocimiento de objetos empleando la fusión Bayesiana de las probabilidades PCA y SIFT obtenidas previamente, se basa en la fusión de las probabilidades PCA y SIFT para determinar en conjunto la clase de una imagen de prueba. Si ambos clasificadores, es decir, el clasificador basado en las características PCA o el basado en las características SIFT determinan con poca probabilidad que la clase de un objeto de prueba es la misma, empleando la fusión Bayesiana para combinar las evidencias de los PCA y los SIFT, se determinará con mayor confianza la clase del objeto de prueba dado.

En el Algoritmo 4.3 Reconocimiento de objetos empleando fusión Bayesiana se realiza el cálculo de las probabilidades Bayesianas P_B dadas las probabilidades PCA y SIFT de entrada ($probaPCA$ representadas por P_P y $probaSIFT$ representadas por P_S). Las probabilidades PCA y SIFT consisten en dos vectores de dimensiones n , don-

de n es el número de objetos de entrenamiento conocidos. Éstos vectores contienen las probabilidades de que el objeto de prueba se clasifique con cada uno de los objetos de entrenamiento, es decir, indican qué tanto se parece el objeto de prueba a los objetos de entrenamiento. El cálculo de las probabilidades PCA y SIFT para el reconocimiento de objetos se explica en las secciones 4.8.1 y 4.8.2. Finalmente, por cada concepto l aprendido en el entrenamiento (tanto para los conceptos individuales como para los colectivos), se obtiene la fusión Bayesiana de las probabilidades $P_P[l]$ y $P_S[l]$ como se muestra en la ecuación 2.4 de la sección 2.7.

Algoritmo 4.3. Reconocimiento de objetos empleando fusión Bayesiana

Datos globales: Número de objetos de entrenamiento, n .

Datos locales: Valor de probabilidad unitaria, P_u ; vector que contiene la fusión Bayesiana de las probabilidades PCA y SIFT, P_B ; índice que apunta a la posición con mayor probabilidad del vector P_B , *ind*.

Datos de entrada: Vector de probabilidades PCA, P_P ; vector de probabilidades SIFT, P_S .

Datos de salida: Clase que obtiene la mayor probabilidad, Cl .

1. $P_u \leftarrow 1/n$
2. **Para** $l \leftarrow 1$ **hasta** n
 - 2.1 Calcular para cada objeto l la fusión Bayesiana empleando la derivación de la regla de Bayes para dos evidencias, $P_P[l]$ y $P_S[l]$.

$$P_B[l] \leftarrow \frac{P_P[l] \times P_S[l] \times P_u}{\left(P_P[l] \times P_S[l] \times P_u\right) + \left((1 - P_P[l]) \times (1 - P_S[l]) \times (1 - P_u)\right)}$$
- 3 Obtener el índice *ind* del valor con mayor probabilidad del vector P_B , y determinar la clase con mayor probabilidad como: $Cl \leftarrow ind$.
- 4 Regresar Cl .

Fin del algoritmo

4.9. Síntesis

En este capítulo se revisaron los tipos de objetos a emplear en el presente trabajo, los cuales son combinaciones de objetos simétricos verticalmente, y no simétricos verticalmente, cuyas texturas pueden ser recurrentes, no recurrentes o lisas.

Asimismo, en este capítulo se proporciona una breve justificación del porqué emplear los tipos de características globales PCA y locales SIFT para conformar a los conceptos individuales y colectivos, ya que ambos tipos de características son complementarias entre sí.

Posteriormente se describieron los cuatro módulos de los que consta cada robot del sistema, es decir, el módulo de entrenamiento individual, el de comunicación, el de análisis y fusión de conceptos y el de reconocimiento de objetos.

El módulo de entrenamiento individual permite a un robot obtener un concepto individual por cada objeto de entrenamiento visto por él. El concepto individual se forma por los conceptos individuales PCA y SIFT que se extraen de una secuencia de imágenes vistas por el robot correspondientes a un objeto en particular en el entrenamiento PCA y en el entrenamiento SIFT, respectivamente.

El módulo de comunicación permite a los robots realizar los dos tipos de aprendizaje cooperativo, el del aprendizaje cooperativo fuera de línea y el del aprendizaje cooperativo en línea. En el primero la compartición de conceptos se realiza una vez que el robot ha realizado el entrenamiento individual para aprender conceptos individuales de todos los objetos de entrenamiento observados por él mismo. En el aprendizaje cooperativo en línea, la compartición de conceptos individuales se realiza después de que en el entrenamiento individual se ha aprendido un concepto por cada objeto de entrenamiento.

El módulo de análisis y fusión de conceptos permite detectar tres tipos de información entre los conceptos individuales propios y compartidos por los robots, es decir, la existencia de información coincidente, de información complementaria y de información confusa. Por información coincidente nos referimos a que los conceptos que se están analizando corresponden al mismo objeto, por tanto una vez detectada la coincidencia entre

los conceptos se realiza la fusión de datos consistente en agregar la nueva información no existente en alguno de los conceptos, lo cuál permite tener una representación más completa del objeto en cuestión. Por información complementaria se entiende que el concepto compartido es completamente distinto a los conceptos individuales existentes en el robot actual, es decir, el objeto aprendido por el robot j es un nuevo objeto para el robot i , y por tanto la fusión necesaria implica agregar el concepto compartido a los conceptos colectivos del robot i . Por información confusa se entiende que los dos robots aprendieron objetos que son similares o por forma o por características locales SIFT, en este caso, la fusión de datos a realizar consiste en agregar el concepto compartido que generó la confusión al conjunto de conceptos del robot actual, ya que se considera como un nuevo objeto aún cuando es similar en alguna característica a al menos uno de los objetos previamente aprendidos por el robot actual. A los conceptos resultantes de la fusión de datos se les conoce como conceptos colectivos.

El módulo de reconocimiento de objetos permite emplear tanto los conceptos individuales como los conceptos colectivos por separado para obtener la clase de algún objeto de prueba visto por el robot. El módulo de reconocimiento de objetos se divide en tres partes: el reconocimiento empleando únicamente características PCA, el reconocimiento empleando características SIFT, y el reconocimiento empleando la fusión Bayesiana de las características PCA y SIFT. En este último se combinan las evidencias PCA y SIFT para determinar con mayor confianza la clase del objeto de pruebas dado. El reconocimiento de objetos empleando la fusión Bayesiana, es el que permite a los robots determinar finalmente la clase de los objetos de prueba.

El enfoque propuesto contiene varios aspectos novedosos.

1. Permite aprender cooperativamente conceptos de objetos a partir de la información adquirida individualmente por los robots del sistema; con lo anterior, los robots enriquecen sus conceptos individuales fusionándolos con los conceptos compartidos por el otro robot del sistema. Por lo tanto, los robots pueden aprender conceptos de objetos no vistos por ellos mismos durante el entrenamiento.

2. Los robots aprenden en línea empleando aprendizaje no-supervisado tanto conceptos individuales como colectivos sin conocer la cantidad así como el tipo de objetos a aprender, es decir, un robot puede observar a más objetos en el entrenamiento u observar a un mismo objeto en más de una ocasión, u observar nuevos objetos.
3. Se utilizan características globales PCA y locales SIFT que son complementarias entre sí y se transforman a probabilidades mediante funciones de distancia. Lo anterior permite: realizar el análisis y fusión de conceptos para determinar la existencia de información coincidente, complementaria y confusa; y realizar la fusión Bayesiana de las características PCA y SIFT para el reconocimiento de objetos.

Capítulo 5

Experimentos y Resultados

En este capítulo presentamos los experimentos realizados divididos en tres tipos: experimentos de aprendizaje individual de conceptos, experimentos de aprendizaje cooperativo de conceptos y experimentos generales de aprendizaje cooperativo de conceptos.

- **Experimentos de aprendizaje individual de conceptos:** Un sólo robot aprende conceptos individuales de distintos objetos.
- **Experimentos por casos de aprendizaje cooperativo de conceptos:** Se prueba de forma individual, es decir, por caso, la detección de los tres tipos de información y su fusión en un único concepto colectivo.
- **Experimentos combinados de aprendizaje cooperativo de conceptos:** Se combinan los tres tipos de información en cada uno de los experimentos. Además, el aprendizaje cooperativo de conceptos se realiza tanto fuera de línea como en línea.

Por cada experimento se presentan los resultados obtenidos en el reconocimiento de objetos y se realiza una evaluación cuantitativa de los conceptos individuales y colectivos adquiridos utilizando la métrica definida en la siguiente sección.

5.1. Criterios de evaluación

Los criterios de evaluación se basan en los porcentajes de clasificación obtenidos aplicando cada uno de los conceptos, tanto individuales como colectivos, adquiridos por los robots del sistema. Los porcentajes de evaluación se determinan empleando de forma independiente los resultados obtenidos en el reconocimiento de objetos usando los clasificadores PCA, SIFT y la fusión Bayesiana de ambos.

Los porcentajes de clasificación (PC) para el clasificador basado en las características PCA, para el clasificador basado en las características SIFT y para la fusión Bayesiana SIFT-PCA, se obtienen de acuerdo a la ecuación 5.1:

$$PC = \frac{N_C}{N_T} \quad (5.1)$$

donde N_C es el número de imágenes en donde el objeto se clasificó correctamente con una probabilidad mayor o igual a 0.6 (criterio establecido para aceptar como correcta una clasificación), N_T es el número total de imágenes consideradas en donde aparece un objeto de prueba completo.

5.2. Experimentos de aprendizaje individual de conceptos

En esta sección describimos los principales experimentos de aprendizaje individual de conceptos y el uso de dichos conceptos para el reconocimiento de objetos empleando un único robot del sistema multi-robot. El objetivo de estos experimentos fue medir la capacidad del reconocimiento de objetos empleando de forma separada las características globales PCA, las características locales SIFT y la fusión Bayesiana de ambas.

En estos experimentos se utilizaron los seis objetos distintos que se muestran en la figura 5.1. Dichos objetos son simétricos verticalmente y por sus características locales hay objetos no recurrentes, e.g., Figura 5.1 (b)-(f), y objetos sin características locales, como es el caso del objeto de la Figura 5.1 (a).

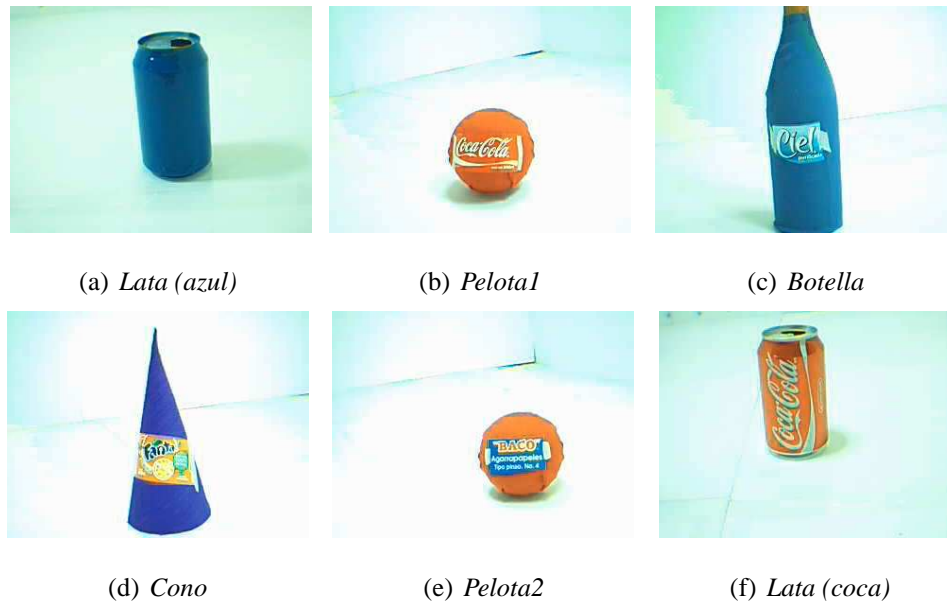


Figura 5.1: Objetos de entrenamiento empleados en los experimentos individuales.

En estos experimentos los objetos se colocaron en línea separados por una distancia de 30 *cm* entre sí aproximadamente. La distancia de 30 *cm* entre los objetos permite que el robot no observe a más de un objeto durante el entrenamiento.

A continuación se presenta el entrenamiento individual y los resultados de reconocimiento de objetos de un experimento que representa de forma general a los experimentos individuales realizados.

5.2.1. Entrenamiento individual

El entrenamiento individual de un robot se realiza empleando los seis objetos que se muestran en la figura 5.1. En este experimento el robot siguió una trayectoria en línea recta de forma paralela a la ubicación de los objetos de entrenamiento con su cámara apuntando hacia los objetos. La distancia promedio entre la trayectoria seguida por el robot y los objetos fue de 40 *cm* aproximadamente. En promedio, el robot capturó una imagen por cada 2 *cm* de distancia avanzados.

Del total de imágenes capturadas por el robot (120 imágenes), únicamente 71 fueron

seleccionadas por el robot por contener algún objeto de interés empleando el esquema de detección de objetos de la sección 4.5.1. De las imágenes seleccionadas el robot detectó automáticamente seis bloques de imágenes, correspondientes a los seis objetos de entrenamiento. El número de imágenes que cada bloque de imágenes puede contener es variable, pues el robot captura y selecciona por si mismo las imágenes que contienen a algún objeto. En este caso influye el ruido que pueda existir en las imágenes capturadas, por ejemplo, el brillo, bajo contraste entre el objeto y el fondo del ambiente, así como el tamaño de los objetos que no es homogéneo. Cada bloque de imágenes detectado por el robot contiene el siguiente número de imágenes de entrenamiento: *lata (azul)*, 8 imágenes; *pelota1*, 14 imágenes; *botella*, 17 imágenes; *cono*, 18 imágenes; *pelota2*, 8 imágenes; y *lata (coca)*, 6 imágenes.

A partir de cada bloque de imágenes, es decir, por cada objeto de entrenamiento, el robot aprende un concepto individual consistente en un vector de dimensión $nEigens$ para las características globales PCA y un conjunto de puntos SIFT para las características locales SIFT (ver sección 4.5).

En la figura 5.2 se muestran las proyecciones de los vectores aprendidos por el robot por cada objeto de entrenamiento en el eigenspacio PCA. De forma correspondiente, los puntos SIFT de cada objeto de entrenamiento se muestran gráficamente en la figura 5.3.




Figura 5.2: Experimento individual: Proyecciones de las siluetas de los objetos de entrenamiento. a) *lata (azul)*, b) *pelota1*, c) *botella*, d) *cono*, e) *pelota2* y f) *lata (coca)*.

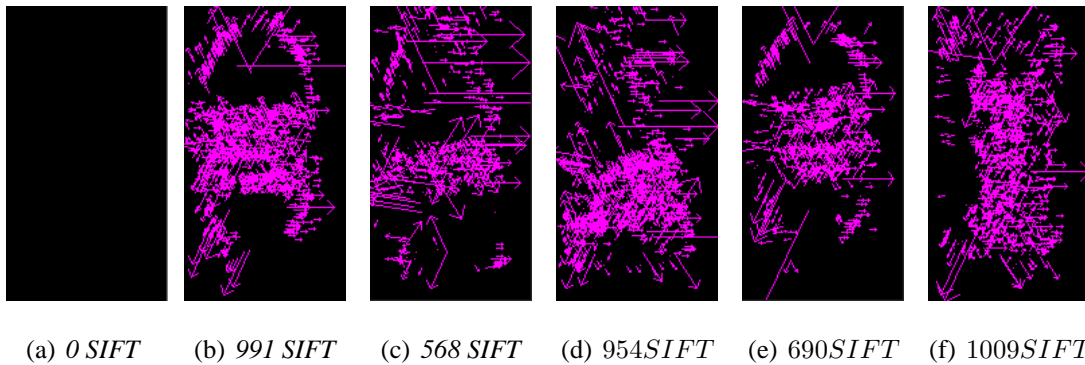


Figura 5.3: Experimento individual: Características SIFT de los objetos de entrenamiento y número de características detectadas por cada objeto. a) *lata (azul)*, b) *pelota1*, c) *botella*, d) *cono*, e) *pelota2* y f) *lata (coca)*. Las bases de las flechas indican la ubicación de los puntos SIFT, el tamaño de las flechas indica la magnitud del gradiente.

5.2.2. Reconocimiento de objetos


Para el reconocimiento de objetos el robot siguió una trayectoria similar a la descrita en el entrenamiento individual en la que los objetos se encuentran en el mismo orden y a una distancia promedio de 40 *cm* del robot. El número de imágenes adquiridas por el robot durante la prueba fue de 95 imágenes, de las cuales 11 corresponden al objeto *lata (azul)*; 12 al objeto *pelota1*; 16 al objeto *botella*; 14 al objeto *cono*; 6 al objeto *pelota2*; 6 al objeto *lata (coca)* y 30 imágenes que contenían objetos incompletos (consideradas como ruido) o fondo del ambiente. Las 30 imágenes antes mencionadas no son clasificadas por el robot pues no contienen objetos. El tiempo total del recorrido fue de aproximadamente 5 minutos.

En la figura 5.4 (a) se muestra la gráfica del reconocimiento de objetos empleando únicamente las características globales PCA aprendidas por el robot. En la parte superior de la gráfica se aprecian los objetos vistos por el robot en cada bloque de imágenes. En la gráfica se presentan las probabilidades de clasificación de cada imagen de prueba para cada objeto de entrenamiento. Las probabilidades de clasificación para el objeto de prueba visto en ese bloque de imágenes en su clase correspondiente, en general, son mayores que

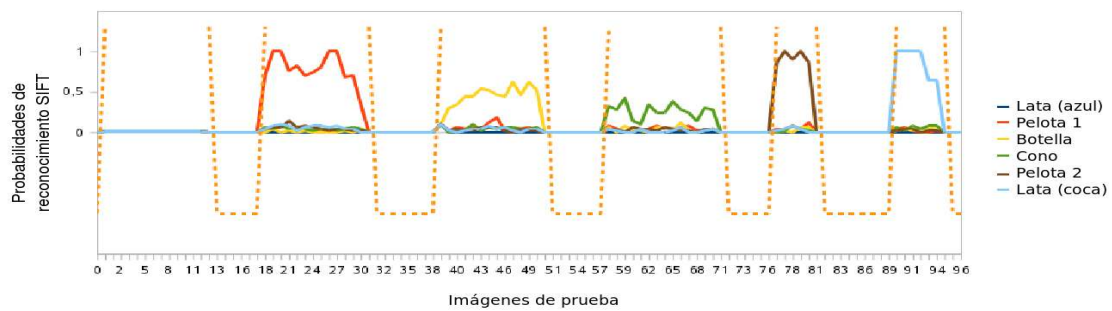
las probabilidades de clasificación para el resto de objetos de entrenamiento. Sin embargo, se observa que el clasificador confunde y atribuye probabilidades de clasificación altas a objetos que tienen forma similar, como es el caso de los objetos *lata (azul)* y *lata (coca)* en los bloques 1 y 6, y de los objetos *pelota1* y *pelota2* en los bloques 2 y 5, respectivamente.

En la figura 5.4 (b) se muestran las gráficas del reconocimiento de objetos empleando únicamente las características locales SIFT. Como se puede apreciar en la gráfica, las características SIFT permiten discriminar entre objetos siempre y cuando el número de características SIFT coincidentes sea alto (del orden de 80 puntos SIFT). Los principales inconvenientes de este tipo de características son: en algunas ocasiones no se pueden obtener características SIFT de los objetos, como ocurre en el objeto *lata (azul)* del bloque 1; el número de características es muy bajo como en el caso del objeto *cono* del bloque 4; dos o más objetos distintos en forma pueden tener las mismas características SIFT y ser confundidos entre sí.

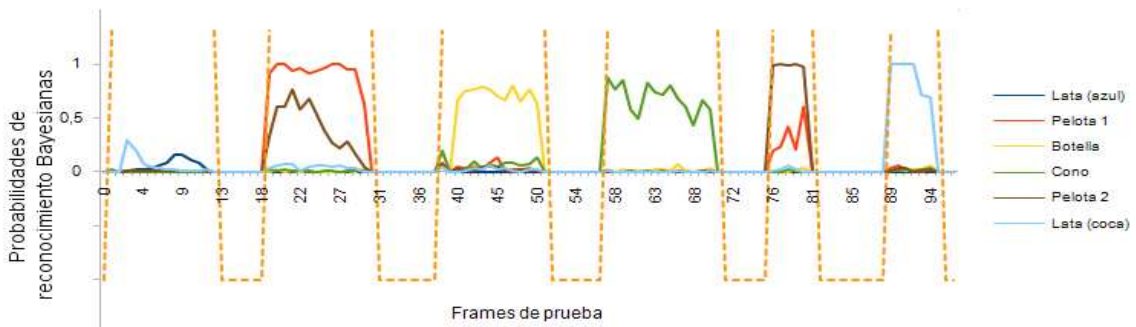
En la figura 5.4 (c) se muestran las gráficas del reconocimiento de objetos empleando la fusión Bayesiana de las características PCA y SIFT previamente aplicadas. La fusión permite abordar los principales inconvenientes que tienen el reconocimiento de objetos por características globales PCA y por características locales SIFT por separado. Por ejemplo, para el caso del objeto *cono* del bloque 4, las características SIFT dieron en promedio para el bloque completo una probabilidad de clasificación igual a 0.26, y al fusionarlas con las probabilidades de clasificación empleando los PCA, se pudo clasificar correctamente al objeto en la mayoría de las imágenes de la secuencia de pruebas con una probabilidad promedio de 0.69. Otro ejemplo ocurre para el objeto *lata (coca)* al que el clasificador PCA confunde con el objeto *lata (azul)*. Sin embargo, al considerar también las probabilidades de clasificación SIFT fue posible clasificar correctamente al objeto con una probabilidad promedio de 0.92 dado que los objetos tenían características SIFT distintas. Para el caso del objeto *lata (azul)*, se observa que la fusión PCA-SIFT no siempre funciona, ya que no es posible determinar la clase del objeto debido a que no se cuenta con características SIFT del objeto (por ser un objeto liso), por lo tanto, no es posible determinar su clase.



(a)



(b)



(c)

Figura 5.4: Experimento individual de reconocimiento. En la parte superior de la imagen se muestran los objetos de prueba y el orden de aparición. a) Probabilidades de clasificación empleando las características globales PCA, b) probabilidades de clasificación empleando las características locales SIFT, c) probabilidades de clasificación empleando la fusión Bayesiana de las características PCA y SIFT.

En la tabla 5.1 se muestran los porcentajes de clasificación obtenidos en el experimento individual de reconocimiento de objetos. En la tabla 5.2 se muestran los porcentajes de clasificación promedio de seis experimentos en los que se varió el número de objetos, el tipo de objetos y el orden de los objetos. De acuerdo a la tabla 5.2 se puede apreciar que al fusionar ambos clasificadores, el porcentaje de clasificación Bayesiana disminuye respecto al porcentaje del clasificador PCA. Sin embargo, como se aprecia en los resultados de cobertura de la sección 5.3.4, los conceptos individuales empleando la fusión Bayesiana son mejores.

Tabla 5.1: Porcentajes de clasificación obtenidos en el experimento individual.

Porcentajes de clasificación del experimento individual		
PCA	SIFT	Fusión Bayesiana (PCA-SIFT)
58 %	49 %	88.2 %

Tabla 5.2: Porcentajes de clasificación promedio obtenidos de seis experimentos individuales.

Porcentajes de clasificación promedio		
PCA	SIFT	Fusión Bayesiana (PCA-SIFT)
84.94 %	67.88 %	80.18 %

En el presente experimento de aprendizaje individual de conceptos se abordaron aquellos casos en los que tanto las características PCA como las características SIFT fallan individualmente. Sin embargo, se demostró experimentalmente que al emplear la fusión Bayesiana de ambas características, es posible detectar correctamente la clase de los objetos en la mayor parte de los casos. Se detectaron problemas de clasificación al emplear la fusión Bayesiana cuando no se puede extraer evidencia SIFT de los objetos de entrenamiento.

5.3. Experimentos por casos de aprendizaje cooperativo de conceptos

En esta sección describimos tres tipos de experimentos en los que se abordan los tres tipos de información por separado, es decir, experimentos con información coincidente, complementaria y confusa. Los objetivos de estos experimentos fueron, que los robots determinen el tipo de información compartida entre ellos, fusionar los conceptos colectivos de acuerdo al tipo de información detectada, y medir la capacidad del reconocimiento de objetos empleando los conceptos individuales y los colectivos adquiridos por los robots del sistema.

A continuación se presentan los experimentos realizados.

5.3.1. Experimento con información coincidente

Para este experimento, dado que los dos robots capturaron imágenes durante el entrenamiento individual de los mismos objetos, la información coincidente ocurre tanto por la forma de los objetos como por las características locales SIFT. El tipo de objetos empleados en la prueba son simétricos verticalmente por su forma y del tipo recurrentes por sus características locales. En la figura 5.5 se muestran los objetos de entrenamiento aprendidos por los dos robots del sistema.

Una vez que cada robot entrenó individualmente empleando las secuencias de imágenes adquiridas por ellos mismos a lo largo de una trayectoria previamente definida, es decir, una vez que los robots aprendieron conceptos individuales de los objetos de entrenamiento como se indica en la sección 4.5.2, ambos robots comparten entre sí sus conceptos individuales para su posterior análisis.

En las tablas 5.3 y 5.4 presentamos los vectores de probabilidades calculados por los robots 1 y 2 durante el experimento. Por cada concepto compartido, cada robot realiza: 1) el pre-análisis de conceptos individuales de la sección 4.7.1 tomando en cuenta a los conceptos actualmente conocidos por el robot que se encuentra realizando el pre-análisis. En




Figura 5.5: Objetos de entrenamiento del experimento con información coincidente. (a) *Cono*, (b) *Botella*, (c) *Pelota* y (d) *Botella 2*. Los cuatro objetos empleados corresponden a la clase de objetos simétricos verticalmente, y por sus características locales pertenecen a la clase de objetos recurrentes.

este punto se obtiene un vector de probabilidades distinto por cada concepto compartido. 2) Cada robot detecta el tipo de información de acuerdo al vector de probabilidades recién calculado y 3) cada robot fusiona conceptos de acuerdo al tipo de información detectada.

Las probabilidades de las tablas 5.3 y 5.4 indican qué tanto se parecen los objetos aprendidos por los robots 1 y 2 empleando las características globales PCA (ver tablas v_P^1 y v_P^2) y las características locales SIFT (ver tablas v_S^1 y v_S^2). En negritas se muestran las probabilidades que indican la existencia de información coincidente entre los objetos vistos por el robot 1 (R1) y los objetos vistos por el robot 2 (R2).

$$ObjCoin_{(k,l)} = \begin{cases} 1 & \text{Si } v_{P_{(k,l)}} \geq umbralProba \text{ y } v_{S_{(k,l)}} \geq umbralProba \\ 0 & \text{En otro caso} \end{cases} \quad (5.2)$$

Donde *umbralProba* es un valor de probabilidad determinado experimentalmente igual a 0.65, dicho valor *umbralProba* es el mismo en todos los experimentos realizados. El valor dado a *umbralProba* fue elegido después de realizar una serie de experimentos en los que se observó que dicho valor de umbral permite detectar cuáles conceptos son coincidentes tanto por forma como por características locales SIFT. Además, el valor de *umbralProba* elegido no permite fusionar conceptos que no corresponden al mismo objeto, es decir, conceptos complementarios o confusos. Por ejemplo, si se hubiera elegido

Tabla 5.3: Vectores de probabilidades PCA y SIFT obtenidos por el robot 1.

Vectores de probabilidades PCA (v_P^1)					Vectores de probabilidades SIFT (v_S^1)				
	Objetos R1					Objetos R1			
Objetos R2 (Compartidos)	<i>Cono</i>	<i>Botella</i>	<i>Pelota</i>	<i>Botella 2</i>	Objetos R2 (Compartidos)	<i>Cono</i>	<i>Botella</i>	<i>Pelota</i>	<i>Botella 2</i>
<i>Cono</i>	0.84	0.38	0.22	0.41	<i>Cono</i>	1.00	0.13	0.36	0.07
<i>Botella</i>	0.48	0.78	0.42	0.62	<i>Botella</i>	0.12	1.00	0.30	0.21
<i>Pelota</i>	0.24	0.46	0.87	0.38	<i>Pelota</i>	0.04	0.10	1.00	0.12
<i>Botella 2</i>	0.40	0.60	0.35	0.70	<i>Botella 2</i>	0.10	0.32	0.10	1.00

Tabla 5.4: Vectores de probabilidades PCA y SIFT obtenidos por el robot 2.

Vectores de probabilidades PCA (v_P^2)					Vectores de probabilidades SIFT (v_S^2)				
	Objetos R2					Objetos R2			
Objetos R1 (Compartidos)	<i>Cono</i>	<i>Botella</i>	<i>Pelota</i>	<i>Botella 2</i>	Objetos R2 (Compartidos)	<i>Cono</i>	<i>Botella</i>	<i>Pelota</i>	<i>Botella 2</i>
<i>Cono</i>	0.84	0.48	0.24	0.42	<i>Cono</i>	1.00	0.07	0.09	0.27
<i>Botella</i>	0.41	0.78	0.47	0.63	<i>Botella</i>	0.20	1.00	0.20	0.20
<i>Pelota</i>	0.23	0.45	0.87	0.33	<i>Pelota</i>	0.01	0.05	1.00	0.04
<i>Botella 2</i>	0.43	0.65	0.38	0.70	<i>Botella 2</i>	0.10	0.15	0.12	1.00

un valor menor al 0.65 para la variable $umbralProba$, el robot 1 habría detectado como conceptos coincidentes además de los marcados en negritas en la tabla 5.3 (v_P^1), a los conceptos *Botella* (concepto compartido por R2) con *Botella 2* (concepto aprendido por R1) y *Botella 2* (concepto compartido por R2) con *Botella* (concepto aprendido por R1). Si se hubiera elegido un valor de $umbralProba$ mayor que 0.65, dos conceptos coincidentes deberían tener un mayor grado de coincidencias tanto por su forma como por sus características locales SIFT para ser fusionados.

Empleando los vectores de probabilidades de las tablas 5.3, 5.4 y la expresión 5.2, ambos robots son capaces de determinar la existencia o no de información coincidente entre los conceptos l y k aprendidos por el robot 1 y 2, respectivamente.

Las tablas 5.3 y 5.4 contienen a los cuatro vectores de probabilidades obtenidos durante el análisis de los conceptos compartidos por los robots 1 y 2, respectivamente. Los renglones de las tablas representan al vector de probabilidades obtenido por cada concepto compartido. Las columnas indican el parecido entre el concepto compartido y el concepto conocido por el robot correspondiente.

La expresión 5.2 permite determinar que un concepto l aprendido por un robot, por ejemplo el robot 1, es coincidente con un concepto k aprendido por otro robot, por ejemplo el robot 2, siempre y cuando las probabilidades $v_{P(k,l)}^1$ y $v_{S(k,l)}^1$ sean mayores o iguales que el valor *umbralProba* en la columna l de la tabla 5.3 (v_P^1 y v_S^1) para el vector de probabilidades k . Este proceso se realiza también en el robot 2 empleando sus vectores de probabilidades correspondientes (ver tabla 5.4).

Una vez determinada la coincidencia entre los conceptos l y k indicada por $ObjCoin_{(k,l)} = 1$, el robot realiza la fusión de conceptos como se presenta en la sección 4.7.2 de información coincidente, con lo cual se van obteniendo paulatinamente los conceptos colectivos en el robot que se encuentra realizando el proceso.

En las gráficas de las figuras 5.6, 5.7 y 5.8 se muestran los resultados de clasificación de objetos empleando los conceptos individuales adquiridos por cada robot del sistema y los resultados de clasificación empleando los conceptos colectivos. La secuencia de pruebas se obtuvo dejando fijo al robot a una distancia de 40 *cm* de los objetos, de modo que capturó imágenes de los objetos que se le presentaron al rotarlos 15° cada vez. En total el robot capturó 25 imágenes por cada objeto de pruebas. En las gráficas de probabilidades se ilustra el promedio con el cual cada robot empleando sus conceptos individuales y colectivos, reconoce al bloque de imágenes de cada objeto de prueba.

Como se muestra en la gráfica 5.7, las probabilidades de clasificación SIFT de los objetos *Cono* y *Botella 2* empleando los conceptos individuales son muy bajos, del orden de 0.4, debido a que estos objetos contienen pocas variaciones en sus texturas, por lo




Figura 5.6: Probabilidades de clasificación PCA del experimento con información coincidente. En el experimento los dos robots aprendieron los mismos objetos de entrenamiento a partir de secuencias de entrenamiento distintas. Las barras indican las probabilidades de reconocimiento PCA empleando los conceptos individuales y los colectivos de cada robot.

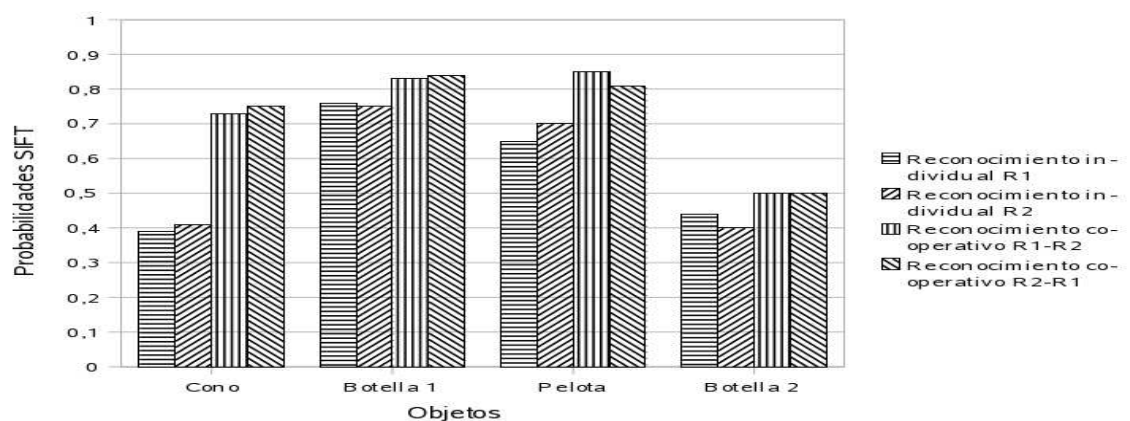


Figura 5.7: Probabilidades de clasificación SIFT del experimento con información coincidente. Los conceptos colectivos empleados para obtener las barras de probabilidades R1-R2 y R2-R1 se obtienen a partir del promedio de los SIFT coincidentes más los SIFT complementarios entre los conceptos individuales coincidentes de cada robot.

cual no contienen gran cantidad de puntos SIFT que permitan su reconocimiento individual. Sin embargo, puede observarse que al emplear la fusión de conceptos individuales SIFT para éstos objetos coincidentes, las probabilidades de clasificación SIFT aumentan

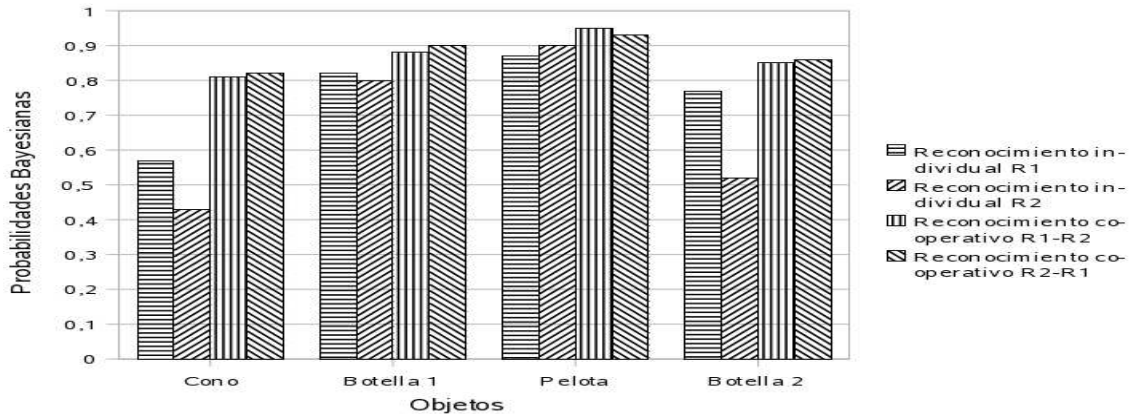


Figura 5.8: Probabilidades de clasificación Bayesianas resultantes de la fusión de las probabilidades de clasificación PCA y SIFT.

permitiendo para el caso del objeto *Cono* el reconocimiento del bloque de imágenes correspondientes empleando los conceptos colectivos R1-R2 y R2-R1 con una probabilidad superior a 0.67.

Los porcentajes de clasificación empleando los conceptos individuales y los colectivos se proporcionan en la tabla 5.5. Los porcentajes de clasificación se calculan como se indica en la sección 5.1, es decir, se obtienen como la razón de la cantidad de imágenes bien clasificadas que contienen a un objeto completo (con probabilidades superiores a 0.6) entre todas las imágenes de prueba que contienen a un objeto completo. Los porcentajes de clasificación se obtienen para evaluar el desempeño de los conceptos individuales y colectivos en una tarea de reconocimiento de objetos.

Tabla 5.5: Porcentajes de clasificación del experimento con información coincidente.

Porcentajes de Clasificación				
	R1	R2	R1-R2	R2-R1
PCA	100.00 %	100.00 %	100.00 %	100.00 %
SIFT	35.71 %	40.81 %	69.38 %	67.34 %
Bayes	80.61 %	58.16 %	95.91 %	96.93 %

Discusión y análisis. En los resultados de reconocimiento empleando los conceptos

colectivos R1-R2 y R2-R1, se observa una ganancia promedio en términos generales. Las barras R1-R2 y R2-R1 de la gráfica de la figura 5.7, representan la parte SIFT de los conceptos colectivos y se obtienen del promedio de SIFT coincidentes, más los SIFT complementarios del concepto compartido por el otro robot.

En el presente experimento el porcentaje de clasificación PCA fue muy alto en todos los casos, 100.00 %, debido a que los distintos objetos empleados tienen siluetas distintas, lo que permite su correcta clasificación por forma. Por otro lado, los porcentajes de clasificación SIFT empleando los conceptos individuales fue del 35.71 % y del 40.81 % de las imágenes de prueba, y empleando los conceptos colectivos fue del 69.38 % y del 67.34 %. La razón principal por la que los porcentajes de clasificación SIFT son bajos empleando tanto los conceptos individuales como los colectivos, se debe principalmente a la textura de los objetos de prueba, es decir, algunos tienen texturas casi lisas de las cuales no es posible extraer características SIFT. La fusión Bayesiana empleando tanto los conceptos individuales como los colectivos permite mejorar los porcentajes de clasificación obtenidos al emplear únicamente características SIFT para clasificar a las imágenes de prueba. Para el caso de SIFT y Bayes, los porcentajes de clasificación empleando los conceptos colectivos respecto a los individuales mejoran significativamente. En general, es posible detectar coincidencias empleando el método propuesto siempre que los dos robots obtengan durante su recorrido de prueba vistas similares a las de los objetos de entrenamiento.

Los porcentajes de clasificación 95.91 % y 96.93 % obtenidos por los robots 1 y 2 al emplear los conceptos colectivos, son menores que los porcentajes correspondientes obtenidos al emplear únicamente la parte PCA de los conceptos colectivos correspondientes. A pesar de lo anterior, ambos robots clasifican a los objetos empleando la fusión Bayesiana, ya que desconocen el tipo de objetos, es decir, si tienen formas distintas o no, o texturas similares o no, pues la fusión Bayesiana posee mayor evidencia que permite la clasificación en dichos casos.

5.3.2. Experimento con información complementaria

El objetivo de este experimento fue probar la capacidad de los robots para identificar la existencia de información complementaria entre los conceptos propios y los compartidos.

La información complementaria ocurre cuando tanto por la forma de los objetos como por sus características locales SIFT, al menos un objeto de los aprendidos por el robot que compartió sus conceptos individuales es distinto a todos los objetos aprendidos por el robot actual.

En este experimento cada robot capturó imágenes de entrenamiento de dos conjuntos distintos de objetos. En las figuras 5.9 y 5.10 se muestran los objetos aprendidos por los robots 1 y 2 respectivamente.



Figura 5.9: Objetos de entrenamiento aprendidos por el robot 1.




Figura 5.10: Objetos de entrenamiento aprendidos por el robot 2.

La expresión 5.3 permite detectar la existencia de información complementaria entre

los conceptos propios y los compartidos por los robots del sistema.

$$ObjComple_k = \begin{cases} 1 & \text{Si } v_{P(k,l)} < umbralProba \text{ y } v_{S(k,l)} < umbralProba \\ & \forall l, \text{ con } 1 \leq l \leq numObjs \\ 0 & \text{En otro caso} \end{cases} \quad (5.3)$$

Donde k y l pueden representar a los objetos vistos por el robot 1 y 2 respectivamente (o viceversa), $numObjs$ es el número de objetos aprendidos por el robot que se encuentra realizando el análisis, v_P y v_S son los vectores de probabilidades, y $umbralProba$ es un valor de probabilidad determinado experimentalmente igual a 0.65. Por lo tanto, cuando $ObjComple_k = 1$ indicará que el concepto compartido k es complementario a todos los conceptos aprendidos por el robot actual, y por lo tanto se agregará como un nuevo concepto colectivo en el robot actual.

En las tablas 5.6 y 5.7 presentamos los vectores de probabilidades v_P^1 y v_S^1 calculados por el robot 1 al emplear el pre-análisis de conceptos individuales de la sección 4.7.1. En las tablas 5.6 y 5.7 se muestran en conjunto todos los pasos del pre-análisis realizado por el robot 1, es decir, un paso por cada objeto compartido por el robot 2 al robot 1 (representados por los distintos renglones de la tabla). Sin embargo, es importante mencionar, que el proceso real seguido por el robot 1 fue: (i) por cada concepto compartido por el robot 2 ($CcomR2$), se realiza el pre-análisis de conceptos tomando en cuenta a todos los conceptos conocidos hasta ese momento por el robot 1, (ii) se determina el tipo de información que genera el concepto $CcomR2$ empleando los vectores v_P^1 y v_S^1 y las expresiones 4.6, 4.7 y 4.8, y (iii) se realiza la fusión de conceptos correspondiente al tipo de información detectada.

Por lo anterior, en las tablas 5.6 y 5.7 se muestran por renglón (correspondientes a cada concepto $CcomR2$), los resultados de los vectores de probabilidades v_P^1 y v_S^1 obtenidos entre todos los conceptos actualmente conocidos por el robot 1. Además, debido a que todos los conceptos aprendidos por el robot 2 son complementarios a los aprendidos por el robot 1, dichos conceptos ($CcomR2$) se van adquiriendo por el robot 1 en cada paso a razón de la fusión de conceptos complementarios realizada. Los conceptos adquiridos por el robot 1 en cada paso del análisis y fusión de conceptos se ilustran a modo de ejemplo en

la columna indicada por “Nuevos”, la cual se refiere a los nuevos conceptos adquiridos. Es importante mencionar que el robot 1 desconoce la cantidad de nuevos conceptos a adquirir durante el aprendizaje de conceptos colectivos, por lo cual, los nuevos conceptos se incorporan conforme se detectan.

Tabla 5.6: Vectores de probabilidades PCA calculadas por el robot 1.

Vectores de probabilidades PCA (v_P^1)						
Objetos R1						
Conceptos individuales				Nuevos conceptos		
Objetos R2 (compartidos)	<i>Botella</i>	<i>Lata</i>	<i>Florero</i>	<i>Pelota</i>	<i>Botella 2</i>	<i>Delfín</i>
<i>Pelota</i>	0.46	0.57	0.33	-	-	-
<i>Botella 2</i>	0.64	0.59	0.24	0.37	-	-
<i>Delfín</i>	0.46	0.47	0.40	0.44	0.42	-

Tabla 5.7: Matriz de probabilidades SIFT calculadas por el robot 1.

Vectores de probabilidades SIFT (v_S^1)						
Objetos R1						
Conceptos individuales				Nuevos conceptos		
Objetos R2 (compartidos)	<i>Botella</i>	<i>Lata</i>	<i>Florero</i>	<i>Pelota</i>	<i>Botella 2</i>	<i>Delfín</i>
<i>Pelota</i>	0.13	0.13	0.05	-	-	-
<i>Botella 2</i>	0.20	0.22	0.03	0.09	-	-
<i>Delfín</i>	0.24	0.07	0.08	0.07	0.26	-

En la tabla 5.8 se muestran los tipos de información detectada entre los conceptos del robot 1 y 2, por cada vector de probabilidades v_P^1 y v_S^1 calculado por el robot 1 (tablas 5.6 y 5.7). La palabra “Todos” en la columna “Objetos R1”, indica que el concepto de la columna “Objetos R2” es complementario a todos los conceptos conocidos por el robot 1. En la tabla 5.8 se muestran además los valores de los vectores de probabilidades correspondientes a cada objeto C_{comR2} compartido por el robot 2. En la columna “Tipo info.”

se ilustra el tipo de información detectada por el robot 1 para el concepto k compartido por el robot 2.

Tabla 5.8: Tipos de información detectada por el robot 1 (R1) en el experimento con información complementaria. Para $l = 1$ hasta el total de conceptos conocidos por el robot 1 en cada paso del análisis.

Tipos de información detectada por el robot 1.				
Objetos R1	Objetos R2	v_P^1	v_S^1	Tipo info.
Todos	<i>Pelota</i>	$v_{P_{(Pelota,l)}}^1 < 0.65$	$v_{S_{(Pelota,l)}}^1 < 0.65$	Complementaria
Todos	<i>Botella 2</i>	$v_{P_{(Botella2,l)}}^1 < 0.65$	$v_{S_{(Botella2,l)}}^1 < 0.65$	Complementaria
Todos	<i>Delfín</i>	$v_{P_{(Delfin,l)}}^1 < 0.65$	$v_{S_{(Delfin,l)}}^1 < 0.65$	Complementaria

En caso de que el valor dado al umbral *umbralProba* hubiera sido diferente, por ejemplo, igual a 0.5, los conceptos *Botella 2* (compartido por el R2) y *Botella* (aprendido por el R1) habrían sido coincidentes por su forma pero no por sus características SIFT (ver tablas 5.6 y 5.7). Lo mismo ocurriría para los conceptos *Pelota* con *Lata* y *Botella 2* con *Lata*. En estos casos, los conceptos habrían sido detectados como información confusa.

En las tablas 5.9 y 5.10 se presentan los vectores de probabilidades v_P^2 y v_S^2 calculados por el robot 2 durante el análisis de los conceptos compartidos por el robot 1.

Tabla 5.9: Vectores de probabilidades PCA calculados por el robot 2.

Vectores de probabilidades PCA (v_P^2)							
		Objetos R2					
		Conceptos individuales			Nuevos conceptos		
Objetos R1 (compartidos)		<i>Pelota</i>	<i>Botella 2</i>	<i>Delfín</i>	<i>Botella</i>	<i>Lata</i>	<i>Florero</i>
<i>Botella</i>		0.46	0.64	0.46	-	-	-
<i>Lata</i>		0.57	0.59	0.47	0.59	-	-
<i>Florero</i>		0.33	0.24	0.40	0.27	0.31	-

En las gráficas de las figuras 5.11, 5.12 y 5.13, se muestran las probabilidades de clasi-

Tabla 5.10: Vectores de probabilidades SIFT calculados por el robot 2.

Vectores de probabilidades SIFT (v_S^2)							
		Objetos R2					
		Conceptos individuales			Nuevos conceptos		
Objetos R1 (compartidos)		<i>Pelota</i>	<i>Botella 2</i>	<i>Delfín</i>	<i>Botella</i>	<i>Lata</i>	<i>Florero</i>
<i>Botella</i>		0.05	0.16	0.20	-	-	-
<i>Lata</i>		0.07	0.16	0.13	0.55	-	-
<i>Florero</i>		0.04	0.16	0.12	0.39	0.15	-

ficación empleando los conceptos individuales y los colectivos aprendidos por cada robot. El número de imágenes de prueba capturadas por el robot de objetos completos para el reconocimiento de objetos fue de 127. El número de imágenes de prueba por cada bloque de imágenes fue de: 25 imágenes para el objeto *botella*, 25 imágenes para el objeto *lata*, 14 imágenes para el objeto *florero*, 25 para el objeto *pelota*, 25 para el objeto *botella 2* y 13 para el objeto *delfín*. Las barras punteadas corresponden a los errores de clasificación producidos por los clasificadores correspondientes. Estos errores de clasificación ocurren al emplear los conceptos individuales para el reconocimiento de objetos desconocidos, es decir, para reconocer objetos con los cuales un robot no fue entrenado individualmente. Se consideran como errores de clasificación si se obtienen probabilidades de reconocimiento superiores a 0.6 para objetos desconocidos, ya que se confunden y atribuyen probabilidades de clasificación a los objetos que tienen o forma similar o SIFT similares. Esto significa que dar probabilidades de clasificación menores a 0.6 a objetos desconocidos es correcto, pues un robot no es capaz de clasificar correctamente objetos para los cuales no fue entrenado.

En la gráfica de la figura 5.11, se aprecian en las dos primeras columnas los errores de clasificación producidos por los conceptos individuales al intentar reconocer objetos desconocidos. Estos errores ocurren debido a que los PCA proyectan las siluetas de los objetos desconocidos a alguna de las siluetas de los conocidos. Por ejemplo, en los pri-




Figura 5.11: Probabilidades de clasificación PCA del experimento con información complementaria. En el experimento los dos robots aprenden objetos distintos en el entrenamiento. Las barras indican las probabilidades de clasificación empleando los PCA de los conceptos individuales y colectivos. Las barras punteadas indican los errores de clasificación ocurridos al evaluar objetos desconocidos utilizando los conceptos individuales de los robots 1 y 2.




Figura 5.12: Probabilidades de clasificación SIFT del experimento con información complementaria. En este caso, empleando los conceptos individuales SIFT no hay confusión durante el reconocimiento de objetos desconocidos.

meros tres bloques de la gráfica 5.11, el robot 2 desconoce a los objetos *Botella*, *Lata* y *Florero* empleando sus conceptos individuales y los confunde con los objetos *Botella 2*, *Botella 2* y *Delfin* respectivamente. Así mismo, el robot 1 desconoce a los objetos *Pelota*,




Figura 5.13: Probabilidades de clasificación Bayesiana resultantes de la fusión de las probabilidades de clasificación PCA y SIFT. Al fusionar la evidencia de los SIFT y PCA, es posible clasificar a los objetos con mayor confianza. Además, se resuelven los errores de clasificación generados por los PCAs.

Botella 2 y Delfin, y los confunde con los objetos *Lata*, *Botella* y *Botella*.

En la tabla 5.11 se muestran los porcentajes de clasificación obtenidos en el reconocimiento de objetos empleando los conceptos individuales y los colectivos. Los porcentajes de clasificación se obtienen como se indica en la sección 5.1. Sin embargo, para los conceptos individuales también se indican entre paréntesis los porcentajes de clasificación tomando en cuenta únicamente a las imágenes de los objetos de prueba conocidos por cada robot.

Tabla 5.11: Porcentajes de clasificación del experimento con información complementaria.

Porcentajes de Clasificación				
	R1	R2	R1-R2	R2-R1
PCA	43.24 % (100.00 %)	55.86 % (97.91 %)	100.00 %	100.00 %
SIFT	36.04 % (83.33 %)	28.83 % (50.79 %)	64.86 %	64.86 %
Bayes	41.44 % (95.83 %)	56.75 % (100.00 %)	86.48 %	86.48 %

Discusión y análisis. En general se muestra que es posible detectar la existencia de información complementaria utilizando el pre-análisis de conceptos propuesto y la expresión 5.3. También, se muestra que el umbral $umbralProba = 0.65$ permite distinguir para este caso entre objetos que tienen formas semejantes pero que son diferentes. En los resultados de reconocimiento empleando los PCA se observa que en todos los casos el reconocimiento empleando los conceptos individuales es mejor respecto al colectivo. Esto se debe a que entre más objetos distintos se tengan en los conceptos, es más complejo encontrar los componentes principales que expliquen la variabilidad de los datos tanto como sea posible (Johnson (2000)). En el presente trabajo, se utilizan como máximo 6 eigenvectores para representar a los conceptos en el espacio PCA, lo cual permite realizar el procesamiento de las imágenes de prueba en un tiempo razonable (del orden de 1 segundo por imagen). En otros trabajos se utilizan del orden de 100 o más eigenvectores para representar a un objeto (Malagón-Borja (2005)), sin embargo, el número de imágenes empleadas en el entrenamiento es del orden de 1000 o más imágenes de una misma clase.

En los experimentos de reconocimiento empleando la fusión Bayesiana se observa por las probabilidades de clasificación una mejora de los PCA en los tres primeros bloques, y una mejora en los SIFT para los tres últimos bloques de imágenes.

Por los porcentajes de clasificación de la tabla 5.11 se observa una mejora en el reconocimiento de objetos empleando la fusión Bayesiana PCA-SIFT, respecto a usar únicamente los conceptos individuales. Los conceptos colectivos PCA mejoran a los conceptos colectivos SIFT a través de la fusión Bayesiana, alcanzando porcentajes de clasificación de las imágenes de prueba que contienen a un objeto completo superiores al 86.40 %.

5.3.3. Experimentos con información confusa

El objetivo de este tipo de experimentos fue el probar la capacidad de los robots para determinar la existencia de información confusa.

En general, pueden presentarse dos tipos de información confusa, cuando los objetos

se distinguen porque tienen formas distintas pero se parecen por sus características locales, y cuando los objetos tienen la misma forma pero se diferencian por sus características locales. En este último pueden suceder dos situaciones, la primera es que se trate de objetos distintos o del mismo objeto pero los robots no tienen vistas semejantes de él, es decir, sus vistas no se intersectan.

La expresión 5.4 permite determinar la existencia de información confusa entre el concepto del objeto l aprendido por un robot, y el concepto del objeto k aprendido por el otro robot. Sin embargo, con esta expresión no se puede solucionar el caso en el que los robots vieron al mismo objeto desde distintos puntos de vista. De esto se hablará más a detalle en el experimento correspondiente y se indicará la solución propuesta.

$$ObjConfu_{(k,l)} = \begin{cases} 1 & \text{Si } v_{S_{(k,l)}} \geq umbralProba \text{ y } v_{P_{(k,l)}} < umbralProba \text{ (Tipo1)} \\ 1 & \text{Si } v_{P_{(k,l)}} \geq umbralProba \text{ y } v_{S_{(k,l)}} < umbralProba \text{ (Tipo2)} \\ 0 & \text{En otro caso} \end{cases} \quad (5.4)$$

Donde *umbralProba* es un valor de probabilidad determinado experimentalmente igual a 0.65. Por lo tanto, cuando $ObjConfu_{(k,l)} = 1$ indicará que el objeto k es confuso con el objeto l correspondiente, y por lo tanto se agregará como un nuevo concepto colectivo como se muestra en la sección 4.7.4.

A continuación presentamos un experimento por cada caso de información confusa antes mencionado.

5.3.3.1. Objetos confusos del tipo 1: diferente forma, características SIFT similares

En este tipo de experimentos los robots aprendieron objetos cuyas formas eran distintas, pero cuyas características SIFT eran coincidentes. Un ejemplo de este caso se ilustra con los objetos de las figuras 5.14 (a) y 5.15 (a). En este caso el robot determina que el objeto que está generando la confusión en realidad es un nuevo objeto y lo aprende.

En las figuras 5.14 y 5.15 se muestran los objetos de entrenamiento aprendidos por los robots 1 y 2. Ambos pares de objetos contienen objetos con formas distintas pero cuyas características SIFT son similares.




Figura 5.14: Objetos de entrenamiento aprendidos por el robot 1 (R1).




Figura 5.15: Objetos de entrenamiento aprendidos por el robot 2 (R2).

En este experimento indicaremos el análisis realizado por un solo robot, el robot 1, el cual determina la existencia de información confusa entre los conceptos propios y los compartidos por el robot 2.

En la tabla 5.12 se presentan los vectores de probabilidades v_P^1 y v_S^1 calculados por el robot 1 por cada concepto compartido por el robot 2. Los conceptos colectivos adquiridos por el robot 1 en cada paso del análisis y fusión de conceptos se ilustran en la columna llamada “Nuevos”.

Por los resultados de los vectores de probabilidades v_P^1 y v_S^1 de la tabla 5.12, y empleando la ecuación 5.4, el robot 1 fue capaz de determinar la existencia de información confusa tipo 1. En este ejemplo el robot 1 detectó confusión únicamente entre los conceptos de los objetos *lata* y *cono*, aún cuando entre los otros dos objetos aprendidos por los robots (*botella* y *pelota*) también se presentaron características SIFT similares. En ambos casos el robot 1 los trata como objetos distintos, por lo cual los agrega a sus conceptos colectivos como se indica en la sección 4.7.4.

Tabla 5.12: Vectores de probabilidades PCA y SIFT calculados por el robot 1.

Vectores de probabilidades PCA (v_P^1)					Vectores de probabilidades SIFT (v_S^1)				
	Objetos R1					Objetos R1			
	Individuales		Nuevos			Individuales		Nuevos	
Objetos R2 (compartidos)	<i>Lata</i>	<i>Botella</i>	<i>Cono</i>	<i>Pelota</i>	Objetos R2 (compartidos)	<i>Lata</i>	<i>Botella</i>	<i>Cono</i>	<i>Pelota</i>
<i>Cono</i>	0.27	0.30	-	-	<i>Cono</i>	0.87	0.15	-	-
<i>Pelota</i>	0.46	0.45	0.24	-	<i>Pelota</i>	0.31	0.20	0.29	-

A continuación, en las figuras 5.16, 5.17 y 5.18, presentamos las gráficas de probabilidades de clasificación obtenidas en las pruebas de reconocimiento de objetos. La secuencia de prueba consistió de 57 imágenes capturadas por el robot que contienen objetos completos. En este caso el robot detectó cuatro bloques de imágenes en la secuencia de prueba. Cada bloque de imágenes detectado contiene el siguiente número de imágenes: 17 imágenes contienen al objeto *lata*, 12 al objeto *botella*, 15 al objeto *cono* y 13 al objeto *pelota*.

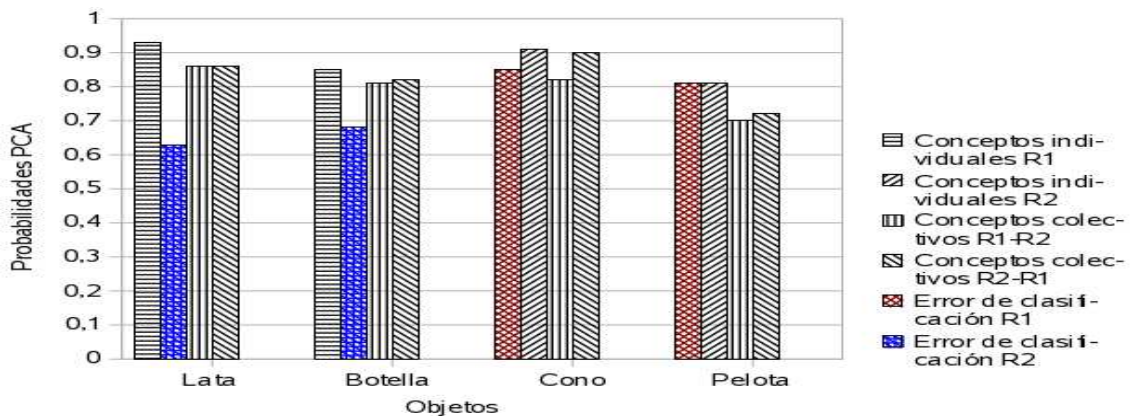


Figura 5.16: Probabilidades de clasificación PCA del experimento con información confusa tipo 1. En el experimento los dos robots aprendieron objetos distintos por forma pero similares por sus características SIFT.




Figura 5.17: Probabilidades de clasificación SIFT del experimento con información confusa tipo 1. En este caso ningún robot comete errores de clasificación a pesar de que los distintos objetos tienen SIFT similares.

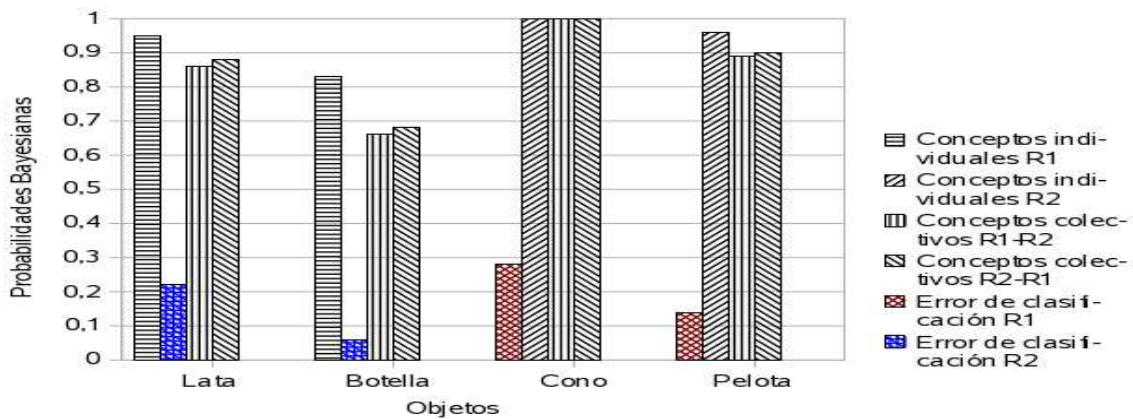


Figura 5.18: Probabilidades de clasificación Bayesiana del experimento con información confusa tipo 1. Al fusionar las características PCA y SIFT ya no ocurren errores de clasificación.

En las figuras 5.16, 5.17 y 5.18, las barras indican las probabilidades de clasificación. Las barras punteadas indican los errores de clasificación ocurridos al evaluar objetos desconocidos empleando los conceptos individuales de los robots 1 y 2. En la gráfica de la figura 5.16, el robot 2 comete errores de clasificación con los objetos *Lata* y *Botella* pues los confunde con los objetos *Pelota* y *Cono* respectivamente. El robot 1 comete errores con los objetos *Cono* y *Pelota* confundiéndolos con los objetos *Botella* y *Lata*. En la

gráfica de la figura 5.17, ningún robot comete errores de clasificación a pesar de que los distintos objetos tienen características SIFT similares. Lo anterior se debe únicamente al punto de vista desde el cuál se capturaron las imágenes de prueba de los distintos objetos. En el primer bloque el robot 2 confunde al objeto *Lata* con el objeto *Cono* con una probabilidad promedio de 0.44, y en el tercer bloque el robot 1 confunde al objeto *Cono* con el objeto *Lata* con una probabilidad de 0.33. Al emplear la fusión Bayesiana (ver figura 5.18), se observa que los errores de clasificación generados por el PCA dejan de ser errores de clasificación después de la fusión. Por lo tanto, en este caso ningún robot clasifica objetos para los cuales no fue entrenado de manera individual. Sin embargo, empleando los conceptos colectivos, ambos robots son capaces de clasificar a todos los objetos de prueba de manera satisfactoria.

Los porcentajes de clasificación del experimento se muestran en la tabla 5.13. Los porcentajes se obtuvieron como se indica en la sección 5.1, a partir de la cantidad de imágenes de prueba clasificadas por cada robot con una probabilidad mayor o igual a 0.6 sobre el total de imágenes de prueba. Entre paréntesis se indican los porcentajes de clasificación de los objetos conocidos por los robots de forma individual sobre el total de imágenes de prueba de dichos objetos.

Tabla 5.13: Porcentajes de clasificación del experimento con información confusa tipo 1.

Porcentajes de Clasificación				
	R1 (individual)	R2 (individual)	R1 (colectivo)	R2 (colectivo)
PCA	50.88 % (100.00 %)	49.12 % (100.00 %)	100.00 %	100.00 %
SIFT	42.11 % (82.75 %)	49.12 % (100.00 %)	91.22 %	89.47 %
Bayes	50.88 % (100.00 %)	49.12 % (100.00 %)	92.22 %	92.98 %

Discusión y análisis. En las barras R1-R2 y R2-R1 de probabilidades PCA de la figura 5.16, se observa que a pesar de que ambos robots contienen en teoría los mismos conceptos colectivos para los objetos, en la mayor parte de los casos, la barra R2-R1 proporciona

mejores probabilidades de clasificación respecto a las probabilidades de las barras R1-R2. Sin embargo, al emplearse los conceptos colectivos PCA para el reconocimiento de objetos, en ambos casos se obtienen porcentajes de clasificación del 100.00 %.

En los resultados de la tabla 5.13 de porcentajes de clasificación, se observa que empleando los conceptos individuales cada robot es capaz de reconocer a los objetos de prueba con los que fue entrenado en el 100.00 % de las imágenes de prueba con la fusión Bayesiana. Sin embargo, en las barras R1-R2 y R2-R1 se observa que al agregar los conceptos de los objetos confusos, dichos porcentajes se reducen hasta en un 8.00 %.

Si ambos robots fueran capaces de detectar que todos los objetos de entrenamiento tienen formas distintas, podrían aplicar únicamente el clasificador PCA para clasificar a los objetos de prueba. Sin embargo, los robots desconocen dicha información, por lo tanto, es necesaria la fusión Bayesiana, la cuál permite clasificar con mayor grado de certidumbre a los objetos de prueba. En la tabla 5.13 se observa que los porcentajes de clasificación obtenidos al emplear los conceptos colectivos y la fusión Bayesiana son de 92.22 % y 92.98 % de las imágenes de prueba.

5.3.3.2. Objetos confusos del tipo 2: forma similar, características SIFT diferentes

En estos experimentos los robots aprenden objetos cuya forma es semejante; sin embargo, por sus características locales SIFT se desconoce si se tienen vistas distintas de un mismo objeto o si en realidad son dos objetos distintos debido a la poca información proporcionada por los SIFT.

En las figuras 5.19 (a) y (b), se aprecia un ejemplo en el que se tienen dos secuencias de vistas distintas de un mismo objeto, y a pesar de tener una región con cierta coincidencia entre sí, realizando el análisis aplicado hasta el momento empleando los vectores de probabilidades PCA (v_P) y SIFT (v_S) y la expresión 5.4, el robot determinará que se trata de objetos distintos y por tanto los tratará como información complementaria.

Para que un robot pueda resolver lo antes mencionado determinando que se trata de un mismo objeto, es necesaria más evidencia que permita corroborar la hipótesis de que ambos conceptos (los que se encuentran en el caso confuso del tipo 2), corresponden al



Figura 5.19: Objetos de entrenamiento aprendidos por los robots 1 y 2 para el experimento que contiene información confusa del tipo 2, es decir, misma forma, características SIFT distintas.

mismo objeto, o desecharla e indicar que se trata de objetos distintos. Para resolver este caso, en el presente trabajo se supone que uno de los robots o un tercer robot es capaz de obtener automáticamente una tercer vista del objeto que genera la confusión, de tal forma que la nueva vista obtenida del objeto sea una imagen “eslabón”, por ejemplo la vista del objeto proporcionada en la figura 5.20, la cuál permite unir a las vistas antes observadas y con ello puede resolverse la confusión.



Figura 5.20: Imagen eslabón *hip-ot*.

A continuación en la tabla 5.14 presentamos los vectores de probabilidades PCA (v_p^1)

y SIFT (v_S^1) resultado del pre-análisis de conceptos del robot 1, empleando el concepto del objeto *otles* de la figura 5.19 (a) aprendido por el robot 1, el concepto del objeto *Chip-o* de la figura 5.19 (b) compartido por el robot 2, y el concepto del objeto *hip-ot* de la figura 5.20 compartido por un tercer robot.

Tabla 5.14: Vectores de probabilidades PCA y SIFT para el experimento con información confusa del tipo 2.

Vectores de probabilidades PCA (v_P^1)			Vectores de probabilidades SIFT (v_S^1)		
	Conceptos R1			Conceptos R1	
Conceptos compartidos	<i>otles</i>	Nuevo (<i>Chip-o</i>)	Conceptos compartidos	<i>otles</i>	Nuevo (<i>Chip-o</i>)
<i>Chip-o</i> _{R2}	0.82	-	<i>Chip-o</i> _{R2}	0.34	-
<i>hip-ot</i> _{R3}	0.91	0.93	<i>hip-ot</i> _{R3}	0.70	1.00

Por las probabilidades obtenidas durante el pre-análisis realizado por el robot 1 del concepto *Chip-o* compartido por el robot 2, el robot 1 es capaz de detectar la confusión del tipo 2 entre el concepto compartido y el concepto conocido por el robot 1 empleando la expresión 5.4, es decir, $v_{P_{(Chip-o, otles)}}^1 = 0.82 \geq umbralProba$ y $v_{S_{(Chip-o, otles)}}^1 = 0.34 < umbralProba$. Por lo tanto, el concepto del objeto que genera la confusión tiene forma similar a la del concepto del objeto conocido por el robot 1, pero por sus características locales son distintos entre sí. En este punto el robot 1 considera a los dos conceptos como diferentes, por lo tanto, la confusión se resuelve empleando la fusión de conceptos como en el caso de la información complementaria descrita en la sección 4.7.3, es decir, el concepto del objeto *Chip-o* se agrega como un nuevo concepto colectivo del robot 1.

Por los resultados del segundo vector de probabilidades de la tabla 5.14, en el que se analiza el concepto compartido por el tercer robot (*hip-ot*), puede observarse el cómo los dos conceptos que en principio se consideraron como distintos, *otles* y *Chip-o*, resultan ser coincidentes con el concepto del objeto “eslabón”, *hip-ot*, tanto por forma (PCA) como por SIFT. Por lo tanto, el siguiente paso consiste en fusionar los tres conceptos en uno solo de acuerdo a la fusión de conceptos coincidentes de la sección 4.7.2.

Discusión y análisis. En el presente experimento se ilustra un ejemplo del cómo es posible resolver los casos confusos del tipo 2, para determinar si se trata del mismo objeto o de objetos distintos. En este experimento se supone que un tercer robot es capaz de obtener automáticamente una tercer vista de un objeto, la cual puede o no ser una imagen “eslabón”. En este experimento se emplearon los conceptos adquiridos por tres robots, en donde cada uno aprendió conceptos de vistas distintas del mismo objeto. Por los resultados del segundo vector de probabilidades de la tabla 5.14, el robot 1 fue capaz de determinar la existencia de información coincidente entre los conceptos conocidos hasta ese momento por el robot 1 y el concepto compartido por el tercer robot, lo cual se resuelve empleando la fusión de conceptos coincidentes.

5.3.4. Calidad de los conceptos individuales y colectivos, en términos de su cobertura

En esta sección se presentan los resultados de seis experimentos que indican la cobertura de los conceptos individuales comparada con la de los conceptos colectivos durante la tarea de reconocimiento de objetos.

Para obtener valores que permitan comparar cuantitativamente ambos tipos de conceptos, en cada experimento los dos robots aprendieron cuatro conceptos de los mismos cuatro objetos empleados en dicho experimento. Los objetos a aprender por los robots se variaron en cada experimento. Por lo tanto, durante el análisis y fusión de conceptos, ambos robots determinaron la existencia de información coincidente. Al final de cada experimento, los dos robots aprendieron tanto individual como colectivamente cuatro conceptos. Todos los conceptos aprendidos por los robots en cada experimento se probaron con la misma secuencia de prueba. En la gráfica de la figura 5.21 se presentan los porcentajes promedio obtenidos por los robots al emplear la parte PCA de sus conceptos individuales y colectivos en el reconocimiento de objetos. En la gráfica 5.21 se indican los porcentajes promedio del número de imágenes bien clasificadas en los seis experimentos (*correctos*), los porcentajes promedio del número de imágenes no detectadas o no clasificadas (*no de-*

tectados), el porcentaje promedio de falsos positivos por cada concepto (*falsos pos.*), y el porcentaje promedio de imágenes que no corresponden a la clase y sin embargo fueron clasificadas con probabilidades mayores o iguales a 0.6 (*arriba 0.6*). En la gráfica 5.22 se presentan los porcentajes promedio obtenidos por los robots al emplear la parte SIFT de sus conceptos, y en la gráfica 5.23 se muestran los porcentajes promedio obtenidos al emplear la fusión Bayesiana.




Figura 5.21: Porcentajes promedio de cobertura empleando la parte PCA de los conceptos individuales y colectivos.




Figura 5.22: Porcentajes promedio de cobertura empleando la parte SIFT de los conceptos individuales y colectivos.

Como puede observarse en las gráficas de las figuras 5.21, 5.22 y 5.23, los porcentajes

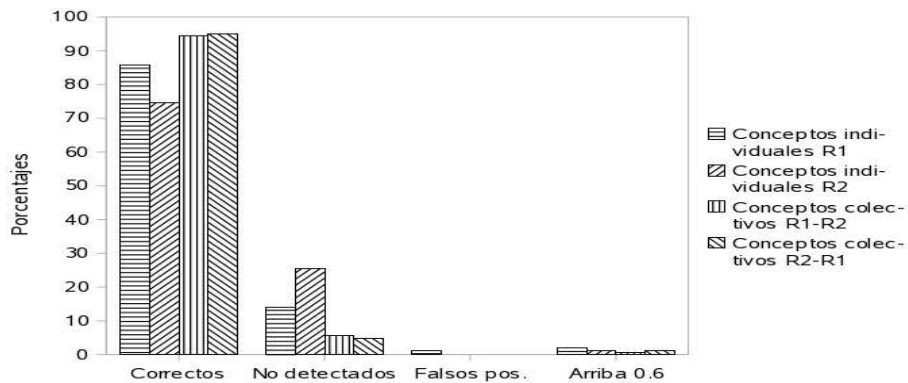


Figura 5.23: Porcentajes promedio de cobertura empleando la fusión Bayesiana de las probabilidades PCA y SIFT de los conceptos individuales y colectivos.

promedio de clasificación que indican la cantidad de imágenes bien clasificadas (*correctos*) empleando los conceptos colectivos R1 y R2 para el reconocimiento de objetos, en general son mayores que los porcentajes de clasificación empleando los conceptos individuales. Para PCA hay una mejora en el porcentaje de clasificación hasta del 2.56 %, para SIFT hay una mejora máxima del 13.79 %, y al emplear la fusión Bayesiana de los conceptos colectivos hay una mejora máxima del **20.62 %**. Esto demuestra que los conceptos colectivos son de mejor calidad comparados con los conceptos individuales al contener mayor cantidad de información adquirida desde diferentes puntos de vista, lo cuál permite reconocer a los objetos de prueba con mayor precisión. Por lo anterior, los porcentajes del número de imágenes no detectadas o clasificadas es menor al emplear los conceptos colectivos respecto al emplear los conceptos individuales. Los porcentajes promedio de falsos positivos al emplear los conceptos individuales son: 14.42 % para PCA, 0.64 % para los SIFT, y 0.64 % empleando la fusión Bayesiana. Los porcentajes promedio de falsos positivos al emplear los conceptos colectivos son: 13.14 % para PCA, 0.00 % para SIFT y 0.00 % empleando la fusión Bayesiana. En la columna de *arriba 0.6* de la figura 5.21 se observa que el número de imágenes clasificadas con una probabilidad mayor o igual a 0.6 y que no corresponden a la clase es mayor por 13.44 % al emplear los conceptos colectivos respecto a los individuales. Sin embargo, lo anterior no influye en la correcta

clasificación de los objetos de prueba como lo indica la columna *correctos*. En las figuras 5.22 y 5.23 se observa una reducción del número de imágenes clasificadas con probabilidades superiores a 0.6. Empleando los conceptos individuales los porcentajes promedio de imágenes clasificadas con probabilidades superiores a 0.6 % son: 3.53 % para SIFT y 1.6 % empleando la fusión Bayesiana; los porcentajes promedio empleando los conceptos colectivos son: 2.24 % para SIFT y 0.96 % empleando la fusión Bayesiana. Cabe hacer notar que el número de imágenes no detectadas se reduce al aplicar los conceptos colectivos, en comparación con el número de imágenes no detectadas al aplicar los conceptos individuales. Por lo anterior, concluimos que los conceptos colectivos son de mejor calidad que los conceptos individuales al cubrir un mayor número de imágenes de los objetos a reconocer.

En general, tanto para los conceptos individuales como los colectivos, al emplear la fusión Bayesiana se observa una ganancia en el porcentaje de clasificación. El promedio de los porcentajes de clasificación empleando los conceptos individuales son: 84.94 % para PCA, 67.88 % para SIFT y 80.18 % empleando la fusión Bayesiana; empleando los conceptos colectivos los porcentajes de clasificación son: 84.29 % para PCA, 74.48 % para SIFT y 94.81 % empleando la fusión Bayesiana. La ganancia promedio en los porcentajes de clasificación Bayesianos empleando los conceptos colectivos respecto a los individuales es del 14.63 %.

5.4. Experimentos combinados de aprendizaje cooperativo de conceptos

El objetivo de los experimentos combinados es el probar la conjunción de los módulos de entrenamiento individual, de comunicación, de análisis y fusión de conceptos, y el de reconocimiento de objetos en sus dos modalidades, es decir, en el aprendizaje cooperativo de conceptos fuera de línea, y en el de aprendizaje cooperativo de conceptos en línea.

5.4.1. Experimento combinado de aprendizaje cooperativo de conceptos (fuera de línea)

En esta prueba, los dos robots del sistema aprenden conceptos de forma individual a partir de los objetos observados por ellos mismos, y es hasta que ambos robots han terminado un recorrido previamente definido, cuando cada uno de ellos comparte sus conceptos con el otro robot del sistema. Una vez compartidos los conceptos individuales, los robots realizan el análisis y la fusión de conceptos. El módulo de reconocimiento de objetos permite probar el desempeño de los conceptos adquiridos de forma individual y colectiva.

Intencionalmente se provocó que los robots aprendieran ciertos objetos ubicados en las trayectorias previamente programadas, con la finalidad de que en el presente experimento los robots trataran los tres tipos de información antes mencionados, es decir, información coincidente, complementaria y confusa al aprender de forma cooperativa.

En la figura 5.24 se presentan los distintos objetos empleados en el experimento. En la figura 5.25 se muestran por tiempos las trayectorias seguidas por los robots durante el entrenamiento individual. El robot que comienza el recorrido se conoce como robot 1 y al segundo robot se le conoce como robot 2. El robot 1 aprendió durante su entrenamiento individual los conceptos de los objetos *florero*, *botella agua*, *lata* y *delfín*. El robot 2 aprendió conceptos de los objetos *florero*, *botella refresco*, *botella* y *cono*. El tiempo del entrenamiento individual del robot 1 fue de 140 segundos, el tiempo del entrenamiento individual del robot 2 fue de 171 segundos. En total si un solo robot realiza los dos recorridos tardaría al menos 311 segundos en aprender conceptos de los distintos objetos de entrenamiento.

Una vez compartidos los conceptos individuales entre los robots del sistema, cada robot realiza el análisis de los conceptos que le fueron compartidos. En las tablas 5.15 y 5.16 se muestran los vectores de probabilidades PCA (v_P^1) y SIFT (v_S^1) obtenidos por el robot 1, uno por cada objeto compartido por el robot 2. En negritas se indican los valores de probabilidades que superan el valor del umbral $umbralProba = 0.65$. Asimismo, en



Figura 5.24: Objetos de entrenamiento empleados en el experimento de aprendizaje cooperativo de conceptos (fuera de línea). a) *Florero*, b) *Botella agua*, c) *Lata*, d) *Delfín*, e) *Botella refresco*, f) *Botella*, y g) *Cono*. En cada objeto se indica qué robot lo aprendió individualmente.

curativas se indican los mayores valores de probabilidades de los vectores que no superan el valor del umbral $umbralProba$. De igual forma en las tablas 5.17 y 5.18 se muestran los vectores de probabilidades PCA (v_p^2) y SIFT (v_s^2) obtenidos por el robot 2.

Tabla 5.15: Vectores de probabilidades PCA calculados por el robot 1 durante el experimento general de aprendizaje cooperativo de conceptos (fuera de línea).

Vectores de probabilidades PCA (v_p^1)							
	Objetos R1						
	Conceptos individuales				Nuevos (conceptos R2)		
Objetos R2	<i>Florero</i>	<i>Botella agua</i>	<i>Lata</i>	<i>Delfín</i>	<i>Botella refresco</i>	<i>Botella</i>	<i>Cono</i>
<i>Florero</i>	0.83	0.41	0.42	0.36	-	-	-
<i>Botella refresco</i>	0.46	0.80	0.53	0.50	-	-	-
<i>Botella</i>	0.41	<i>0.64</i>	0.56	0.46	0.58	-	-
<i>Cono</i>	0.25	0.35	0.19	0.34	0.34	<i>0.36</i>	-

Empleando las expresiones 5.2, 5.3 y 5.4 con un valor de $umbralProba = 0.65$, y los vectores de probabilidades de las tablas 5.15, 5.16, 5.17 y 5.18, ambos robots son capaces de detectar por objeto compartido, es decir, por vector de probabilidades, alguno de los

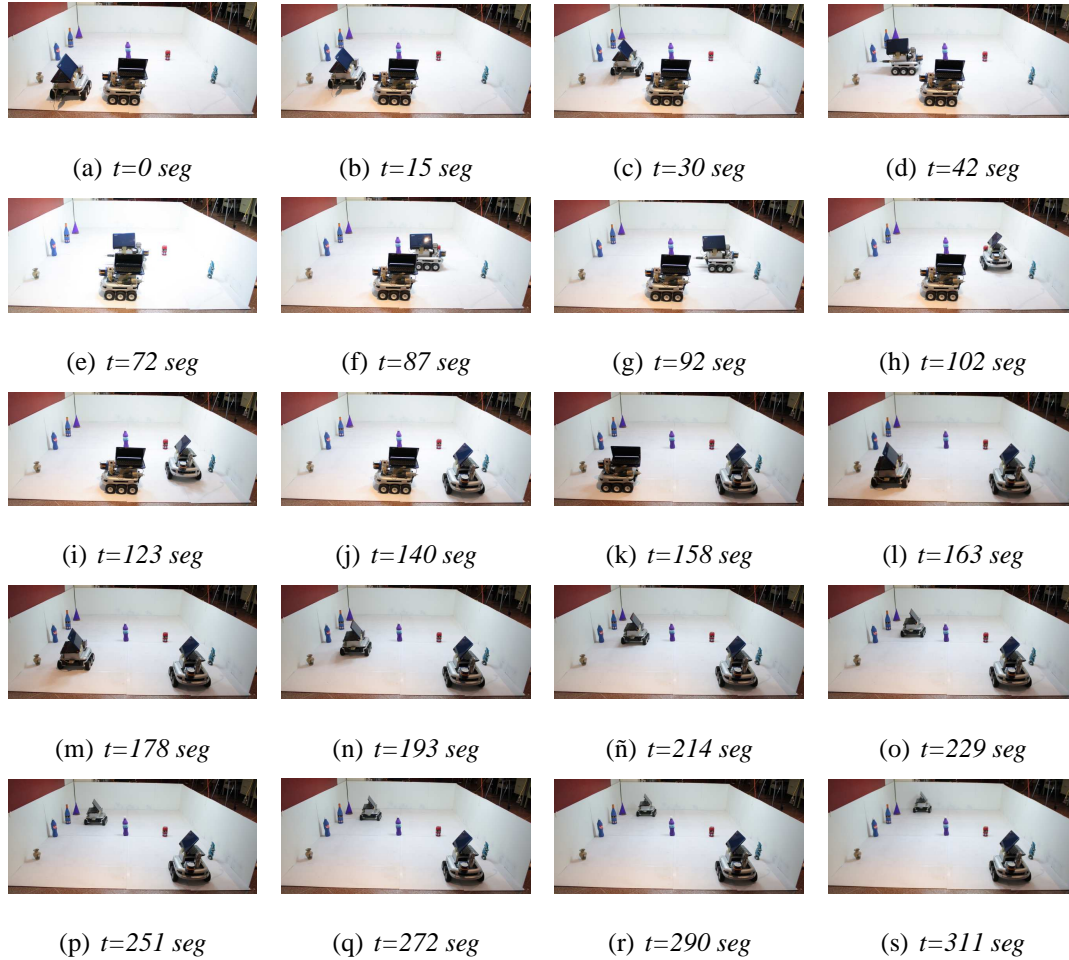


Figura 5.25: Trayectorias de entrenamiento de los robots 1 y 2 del experimento de aprendizaje cooperativo de conceptos fuera de línea.

tres tipos de información.

Es importante recordar que los vectores de las tablas 5.15, 5.16, 5.17 y 5.18, se obtienen al analizar cada concepto compartido respecto a los conceptos actualmente conocidos por los robots.

Analizando los datos de las tablas 5.15 y 5.16 por concepto compartido por el robot 2 (C_{comR2}), se observa lo siguiente:

- Cuando $C_{comR2} = Florero$ entonces $k = 1$, y los valores máximos de los vectores de probabilidades k se encuentran en las posiciones $v_{P(k,1)}^1 = 0.83$ y

Tabla 5.16: Vectores de probabilidades SIFT calculados por el robot 1 durante el experimento general de aprendizaje cooperativo de conceptos (fuera de línea).

Vectores de probabilidades SIFT (v_S^1)							
Objetos R1							
	Conceptos individuales				Nuevos (conceptos R2)		
Objetos R2	<i>Florero</i>	<i>Botella agua</i>	<i>Lata</i>	<i>Delfín</i>	<i>Botella refresco</i>	<i>Botella</i>	<i>Cono</i>
<i>Florero</i>	1.00	0.18	0.10	0.08	-	-	-
<i>Botella refresco</i>	0.02	<i>0.49</i>	0.04	0.06	-	-	-
<i>Botella</i>	0.02	0.13	<i>0.63</i>	0.07	0.12	-	-
<i>Cono</i>	0.02	<i>0.16</i>	0.04	0.08	0.04	0.06	-

Tabla 5.17: Vectores de probabilidades PCA calculados por el robot 2 durante el experimento general de aprendizaje cooperativo de conceptos (fuera de línea).

Vectores de probabilidades PCA (v_P^2)							
Objetos R2							
	Conceptos individuales				Nuevos (conceptos R1)		
Objetos R1	<i>Florero</i>	<i>Botella refresco</i>	<i>Botella</i>	<i>Cono</i>	<i>Botella agua</i>	<i>Lata</i>	<i>Delfín</i>
<i>Florero</i>	0.83	0.48	0.43	0.28	-	-	-
<i>Botella agua</i>	0.44	0.80	0.64	0.35	-	-	-
<i>Lata</i>	0.44	0.53	0.56	0.19	<i>0.58</i>	-	-
<i>Delfín</i>	0.39	<i>0.50</i>	0.46	0.34	0.49	0.41	-

$v_{S(k,1)}^1 = 1.00$ de las tablas correspondientes, donde $l = 1$. Debido a que ambos valores son mayores que el valor $umbralProba = 0.65$, es decir, por la expresión 5.2, el robot 1 considera al concepto compartido k como coincidente con el concepto l . Posteriormente, el robot 1 realiza la fusión de conceptos coincidentes como se indica en la sección 4.7.2.

- Cuando $CcomR2 = Botella\ refresco$ entonces $k = 2$, y los valores máximos de los vectores de probabilidades k se encuentran en las posiciones $v_{P(k,2)}^1 = 0.80$ y $v_{S(k,2)}^1 = 0.49$, donde $l = 2$. Debido a que el concepto del objeto k se parece por

Tabla 5.18: Vectores de probabilidades SIFT calculados por el robot 2 durante el experimento general de aprendizaje cooperativo de conceptos (fuera de línea).

Vectores de probabilidades SIFT (v_S^2)							
Objetos R2							
	Conceptos individuales				Nuevos (conceptos R1)		
Objetos R1	<i>Florero</i>	<i>Botella refresco</i>	<i>Botella</i>	<i>Cono</i>	<i>Botella agua</i>	<i>Lata</i>	<i>Delfín</i>
<i>Florero</i>	1.00	0.07	0.08	0.02	-	-	-
<i>Botella agua</i>	0.03	0.22	0.05	0.06	-	-	-
<i>Lata</i>	0.03	0.18	0.68	0.25	0.07	-	-
<i>Delfín</i>	0.02	0.07	0.28	0.06	0.06	0.05	-

forma al concepto del objeto l pero k no coincide con ningún objeto por sus características SIFT, ya que $v_{S(k,2)}^1 < umbralProba$, el objeto k genera una confusión del tipo 2. En este caso el concepto del objeto k es adquirido por el robot 1 como un nuevo concepto colectivo como se indica en la fusión de conceptos confusos de la sección 4.7.4.

- Cuando $CcomR2 = Botella$ entonces $k = 3$. Los valores máximos de los vectores de probabilidades correspondientes son $v_{P(k,2)}^1 = 0.64$ y $v_{S(k,3)}^1 = 0.63$. En este caso el concepto del objeto k coincide con el concepto del objeto $l = 2$ por su forma, y por sus SIFT coincide con el concepto del objeto $l = 3$. En este caso el robot 1 considera al objeto k como confuso, y lo agrega a sus conceptos colectivos como un nuevo concepto.
- Finalmente, cuando $CcomR2 = Cono$ entonces $k = 4$, y los valores máximos de los vectores de probabilidades k son $v_{P(k,6)}^1 = 0.36$ y $v_{S(k,2)}^1 = 0.16$. Debido a que ambos valores de probabilidad son menores que el $umbralProba$, el robot 1 considera al concepto del objeto k como complementario a todos sus conceptos, y posteriormente realiza la fusión de conceptos correspondiente.

En la tabla 5.19 se muestran los resultados del análisis antes mencionado realizado

por el robot 1. En la tabla 5.20 se muestran los resultados del análisis realizado por el robot 2. En ambas tablas se indican los tipos de información detectada por cada robot.

Tabla 5.19: Tipos de información detectada por el robot 1 por cada concepto compartido por el robot 2.

Tipos de información detectadas por el robot 1				
Objetos R1	Objetos R2	v_P^1	v_S^1	Tipo info.
<i>Florero</i>	<i>Florero</i>	$v_{P(1,1)}^1 = 0.83$	$v_{S(1,1)}^1 = 1.00$	Coincidente
<i>Botella agua</i>	<i>Botella refresco</i>	$v_{P(2,2)}^1 = 0.80$	$v_{S(2,2)}^1 = 0.49$	Confusa tipo 2
Todo <i>l</i>	<i>Botella</i>	$v_{P(3,l)}^1 < 0.65$	$v_{S(3,l)}^1 < 0.65$	Complementaria
Todo <i>l</i>	<i>Cono</i>	$v_{P(4,l)}^1 < 0.65$	$v_{S(4,l)}^1 < 0.65$	Complementaria

Tabla 5.20: Tipos de información detectada por el robot 2 por cada concepto compartido por el robot 1.

Tipos de información detectada por el robot 2				
Objetos R2	Objetos R1	v_P^2	v_S^2	Tipo info.
<i>Florero</i>	<i>Florero</i>	$v_{P(1,1)}^2 = 0.83$	$v_{S(1,1)}^2 = 1.00$	Coincidente
<i>Botella refresco</i>	<i>Botella agua</i>	$v_{P(2,2)}^2 = 0.80$	$v_{S(2,2)}^2 = 0.22$	Confusa tipo 2
<i>Botella</i>	<i>Lata</i>	$v_{P(3,5)}^2 = 0.58$	$v_{S(3,3)}^2 = 0.68$	Confusa tipo 1
Todo <i>l</i>	<i>Delfín</i>	$v_{P(4,l)}^2 < 0.65$	$v_{S(4,l)}^2 < 0.65$	Complementaria

Para probar el desempeño de los conceptos aprendidos por cada robot del sistema, es decir, de los conceptos individuales y colectivos, se programó una nueva trayectoria a los robots con la finalidad de permitirles recorrer el ambiente mientras cada uno iba reconociendo a los objetos observados en su camino. En las pruebas ambos robots tuvieron la misma trayectoria, la cual consistió en recorrer el ambiente alrededor de las paredes del mismo. El orden de aparición de los objetos y el número de imágenes con objetos completos capturadas por cada robot fue: *lata*, 10 imágenes con el R1 y 12 con el R2; *cono*, 13 con R1 y 12 con R2; *botella agua*, 15 con R1 y 18 con R2; *florero*, 9 con R1 y 8 con R2; *botella*, 13 con R1 y 13 con R2; *botella refresco*, 17 con R1 y 17 con R2; y *delfín*, 15

con R1 y 14 con R2. En la figura 5.26 (a) se muestra el estado del ambiente de pruebas en el tiempo $t = 0$, es decir, al inicio de la prueba. En las figuras 5.26 (b) a (t) se muestran las posiciones de los robots 1 y 2 durante la prueba de reconocimiento de objetos cuando los robots se encuentran frente a los distintos objetos.



Figura 5.26: Trayectorias de los robots 1 y 2 durante las pruebas de reconocimiento de objetos empleando los conceptos individuales y colectivos.

En las gráficas de las figuras 5.27, 5.28 y 5.29 se muestran las probabilidades obte-

nidas en el reconocimiento de objetos, en donde cada robot emplea sus conceptos individuales y colectivos para reconocer a los objetos de los cuales va capturando imágenes con su cámara de video. En las gráficas las barras de probabilidades punteadas indican los errores de clasificación. Se considera un error de clasificación cuando un robot clasifica a un objeto desconocido para él, es decir, aquellos objetos que no fueron aprendidos en el entrenamiento individual, con probabilidades superiores a 0.6. En este caso los robots asocian a los objetos desconocidos con alguna de las clases de los objetos conocidos. Los errores de clasificación PCA del robot 1 ocurren en los objetos *cono*, *botella* y *botella refresco*, y los confunde con los objetos *delfín*, *botella agua* y *botella agua*, respectivamente. Los errores de clasificación PCA del robot 2 ocurren en los objetos de prueba *lata*, *botella agua* y *delfín*, y los confunde con los objetos *botella*, *botella refresco* y *botella refresco*, respectivamente. En la gráfica de la figura 5.27, los robots 1 y 2 no comenten errores de clasificación PCA para el objeto *florero*, pues este fue aprendido en el entrenamiento individual de cada robot.




Figura 5.27: Probabilidades de clasificación PCA para el reconocimiento de objetos empleando tanto los conceptos individuales (R1 y R2) y los colectivos (R1-R2 y R2-R1).

En la gráfica de la figura 5.29, se observa que al fusionar las probabilidades PCA y SIFT de reconocimiento, se reducen los errores de clasificación cometidos por los clasificadores individualmente. En el objeto de prueba *botella agua* se observa el único error de clasificación cometido por el robot 2 al emplear sus conceptos individuales para el




Figura 5.28: Probabilidades de clasificación SIFT para el reconocimiento de objetos. El robot 1 comete un error de clasificación en el objeto de prueba *botella* y lo confunde con el objeto *lata*.




Figura 5.29: Probabilidades de clasificación empleando la fusión Bayesiana de las probabilidades de reconocimiento PCA y SIFT.

reconocimiento. En este caso el robot 2 confunde al objeto *botella agua* con el objeto *botella refresco*. Empleando los conceptos colectivos, ambos robots son capaces de clasificar correctamente a todos los objetos de prueba.

En la tabla 5.21 se presentan los porcentajes de clasificación obtenidos en el reconocimiento de objetos al emplear tanto los conceptos individuales como los colectivos para clasificar a los objetos observados en las pruebas. La clasificación se realiza tomando en cuenta únicamente las imágenes de los objetos conocidos por el concepto a evaluar.

Tabla 5.21: Porcentajes de clasificación del reconocimiento de objetos empleando los conceptos individuales y los colectivos adquiridos por los robots en el presente experimento.

Porcentajes de Clasificación				
	R1	R2	R1-R2	R2-R1
PCA	48.91 % (91.83 %)	52.12 % (98.00 %)	95.65 %	98.93 %
SIFT	50.00 % (93.87 %)	52.13 % (98.00 %)	95.65 %	98.93 %
Bayes	48.91 % (91.83 %)	52.12 % (98.00 %)	95.65 %	100.00 %

Discusión y análisis. En el presente experimento cada robot adquirió tres nuevos conceptos, indicados en la columna de “Nuevos” de las tablas 5.15 y 5.17. El análisis realizado por cada robot para la adquisición de los nuevos conceptos se ilustra en las tablas 5.19 y 5.20. En este experimento, el concepto del objeto *florero* fue aprendido individualmente por cada robot, y a su vez, cada robot detectó la coincidencia entre los conceptos de los objetos *florero* propios y compartidos. En general, ambos robots detectaron los mismos tipos de información entre los mismos pares de conceptos, y por tanto, los conceptos colectivos de cada robot contienen una representación similar para los distintos objetos de entrenamiento.

En la gráfica de probabilidades PCA (ver Figura 5.27) se observa que la secuencia de pruebas capturada por el robot 2 pudo clasificarse con mayores probabilidades que la secuencia de imágenes capturada por el robot 1. Lo mismo se observa en las gráficas de probabilidades SIFT (ver Figura 5.28) y Bayesianas (ver Figura 5.29). Lo anterior indica que la secuencia de pruebas capturada por el robot 2 contiene mayor cantidad de imágenes

similares a las adquiridas por los robots en el entrenamiento individual de cada robot. En la columna R2-R1 de la tabla 5.21, se muestra que los porcentajes de clasificación para el reconocimiento de objetos empleando los conceptos colectivos aprendidos por el robot 2 son los más altos, además, al fusionar las probabilidades de clasificación PCA y SIFT, el robot 2 fue capaz de clasificar el 100.00 % de las imágenes de prueba.

5.4.2. Experimento combinado de aprendizaje cooperativo de conceptos (en línea)

En esta prueba los dos robots aprenden por cada objeto observado un concepto individual y lo comparten con el otro robot del sistema, y a su vez reciben el concepto individual aprendido por el otro robot. Posteriormente, cada robot analiza los conceptos individuales, el propio y el compartido, para determinar el tipo de fusión de datos a realizar por cada concepto antes mencionado. Una vez terminada la fusión de conceptos, cada robot continúa avanzando a lo largo de su trayectoria hasta encontrar a un nuevo objeto del cual aprender sus características PCA y SIFT. Posteriormente, vuelve a compartir su concepto individual y a recibir el concepto individual aprendido por el otro robot, y así sucesivamente hasta que cada robot termine de recorrer su trayectoria predefinida, a lo largo de la cual cada uno irá formando sus conceptos colectivos.

En el presente experimento se emplearon los mismos objetos de entrenamiento que en el experimento general de aprendizaje cooperativo de conceptos fuera de línea (ver figura 5.24). En la figura 5.30 se muestran, por tiempos, las trayectorias seguidas por los robots durante el experimento. El tiempo total del aprendizaje cooperativo de conceptos en línea fue de 175 segundos.

Como puede observarse en las trayectorias seguidas por cada robot ilustradas en la figura 5.30, ambos robots avanzan de forma simultánea hasta terminar de ver a un objeto con su cámara de video. Si algún robot deja de ver a un objeto, entonces dicho robot ha terminado de aprender el concepto individual correspondiente. Posteriormente, si el otro robot aún no ha terminado de observar a un objeto, el robot actual se detiene y envía un mensaje al otro robot indicando que se encuentra esperando para compartir conceptos individuales. Una vez que ambos robots han aprendido un concepto individual de los objetos observados por cada uno, comparten el concepto individual recién adquirido con el otro robot miembro del sistema. Finalmente, cada robot analiza el concepto propio y el compartido, realiza las fusiones de conceptos correspondientes, y continúa avanzando en el ambiente hasta encontrar a otro objeto. Al proceso mencionado anteriormente se

le conoce en el presente trabajo como aprendizaje cooperativo de conceptos en línea. En este experimento el robot 1 aprendió individualmente conceptos de los objetos *delfín*, *lata*, *botella agua* y *florero*. Mientras que el robot 2 aprendió individualmente conceptos de los objetos *florero*, *botella refresco*, *botella* y *cono*, en el orden presentado.




Figura 5.30: Trayectorias seguidas por los robots durante el experimento de aprendizaje cooperativo de conceptos en línea. Ambos robots recorren las trayectorias predefinidas de forma simultánea. El robot 1 aprende conceptos individualmente de los objetos *delfín*, *lata*, *botella agua* y *florero*. El robot 2 aprende conceptos de los objetos *florero*, *botella refresco*, *botella* y *cono*.

Una vez compartidos los conceptos individuales, cada robot realiza el análisis del concepto individual propio y el compartido por el otro robot del sistema. En las tablas 5.22 y 5.23 se muestran los vectores de probabilidades PCA (v_P^1) y SIFT (v_S^1) obtenidos por el robot 1. En las tablas 5.24 y 5.25 se muestran los vectores de probabilidades PCA (v_P^2) y SIFT (v_S^2) obtenidos por el robot 2. Los vectores de probabilidades se encuentran separados por pares de vectores para ilustrar el análisis y fusión de conceptos realizado

por cada robot en cada paso del concepto individual propio y el compartido por el otro robot del sistema.

Tabla 5.22: Vectores de probabilidades PCA calculados por el robot 1 durante el experimento de aprendizaje cooperativo en línea.

Vectores de probabilidades PCA (v_p^1)							
	Nuevos (conceptos colectivos R1)						
Objetos R1 y R2	<i>Delfín</i>	<i>Florero</i>	<i>Lata</i>	<i>Botella refresco</i>	<i>Botella agua</i>	<i>Botella</i>	<i>Cono</i>
<i>Delfín</i> _{R1}	-	-	-	-	-	-	-
<i>Florero</i> _{R2}	0.19	-	-	-	-	-	-
<i>Lata</i> _{R1}	0.31	0.26	-	-	-	-	-
<i>Botella refresco</i> _{R2}	0.36	0.28	0.58	-	-	-	-
<i>Botella agua</i> _{R1}	0.43	0.28	0.53	0.73	-	-	-
<i>Botella</i> _{R2}	0.31	0.17	0.56	0.61	0.58	-	-
<i>Florero</i> _{R1}	0.25	0.69	0.42	0.43	0.41	0.32	-
<i>Cono</i> _{R2}	0.31	0.01	0.28	0.28	0.33	0.43	-

Empleando las expresiones 5.2, 5.3 y 5.4 con un valor de $umbralProba = 0.65$, y los vectores de las tablas 5.22, 5.23, 5.24 y 5.25, los robots son capaces de detectar durante el análisis de los conceptos los distintos tipos de información. En las tablas 5.26 y 5.27 se muestran los resultados del análisis realizado por cada uno de los robots. Por cada concepto individual (renglón) se indican los tipos de información detectados durante el análisis. Los tipos de información son empleados para realizar la fusión de conceptos y obtener de esta forma los conceptos colectivos.

Para probar el desempeño de los conceptos individuales y colectivos aprendidos por cada robot, se empleó una trayectoria de prueba similar a la del experimento general de aprendizaje cooperativo de conceptos fuera de línea (ver figura 5.26). Además, el orden de aparición de los objetos a lo largo de la trayectoria fue el mismo. Se realizaron cuatro experimentos de reconocimiento de objetos en línea empleando las condiciones de prueba antes mencionadas. En las gráficas de las figuras 5.31, 5.32 y 5.33 se muestran los pro-

Tabla 5.23: Vectores de probabilidades SIFT calculados por el robot 1 durante el experimento de aprendizaje cooperativo en línea.

Vectores de probabilidades SIFT (v_S^1)							
	Nuevos (conceptos colectivos R1)						
Objetos R1 y R2	<i>Delfín</i>	<i>Florero</i>	<i>Lata</i>	<i>Botella refresco</i>	<i>Botella agua</i>	<i>Botella</i>	<i>Cono</i>
<i>Delfín</i> _{R1}	-	-	-	-	-	-	-
<i>Florero</i> _{R2}	0.09	-	-	-	-	-	-
<i>Lata</i> _{R1}	0.12	0.12	-	-	-	-	-
<i>Botella refresco</i> _{R2}	0.28	0.11	0.40	-	-	-	-
<i>Botella agua</i> _{R1}	0.15	0.59	0.20	0.20	-	-	-
<i>Botella</i> _{R2}	0.08	0.15	0.65	0.04	0.12	-	-
<i>Florero</i> _{R1}	0.16	1.00	0.23	0.10	0.08	0.09	-
<i>Cono</i> _{R2}	0.05	0.28	0.43	0.10	0.14	0.09	-

Tabla 5.24: Vectores de probabilidades PCA calculados por el robot 2 durante el experimento de aprendizaje cooperativo en línea.

Vectores de probabilidades PCA (v_P^2)							
	Nuevos (conceptos colectivos R2)						
Objetos R2 y R1	<i>Florero</i>	<i>Delfín</i>	<i>Botella refresco</i>	<i>Lata</i>	<i>Botella</i>	<i>Botella agua</i>	<i>Cono</i>
<i>Florero</i> _{R2}	-	-	-	-	-	-	-
<i>Delfín</i> _{R1}	0.19	-	-	-	-	-	-
<i>Botella refresco</i> _{R2}	0.28	0.36	-	-	-	-	-
<i>Lata</i> _{R1}	0.26	0.31	0.58	-	-	-	-
<i>Botella</i> _{R2}	0.17	0.31	0.61	0.56	-	-	-
<i>Botella agua</i> _{R1}	0.29	0.44	0.73	0.54	0.58	-	-
<i>Cono</i> _{R2}	0.01	0.31	0.28	0.28	0.43	0.33	-
<i>Florero</i> _{R1}	0.69	0.25	0.43	0.42	0.32	0.41	0.01

Tabla 5.25: Vectores de probabilidades SIFT calculados por el robot 2 durante el experimento de aprendizaje cooperativo en línea.

Vectores de probabilidades SIFT (v_S^2)							
	Nuevos (conceptos colectivos R2)						
Objetos R2 y R1	<i>Florero</i>	<i>Delfín</i>	<i>Botella refresco</i>	<i>Lata</i>	<i>Botella</i>	<i>Botella agua</i>	<i>Cono</i>
<i>Florero</i> _{R2}	-	-	-	-	-	-	-
<i>Delfín</i> _{R1}	0.18	-	-	-	-	-	-
<i>Botella refresco</i> _{R2}	0.11	0.28	-	-	-	-	-
<i>Lata</i> _{R1}	0.12	0.12	0.04	-	-	-	-
<i>Botella</i> _{R2}	0.15	0.08	0,04	0.64	-	-	-
<i>Botella agua</i> _{R1}	0.59	0.15	0.20	0.20	0.12	-	-
<i>Cono</i> _{R2}	0.09	0.05	0.10	0.43	0.09	0.14	-
<i>Florero</i> _{R1}	1.00	0.16	0.10	0.23	0.09	0.08	0.12

Tabla 5.26: Tipos de información detectada por el robot 1 por cada concepto individual propio y compartido por el robot 2.

Tipos de información detectadas por el robot 1				
Objetos R1 y R2	Objetos relacionados	v_P^1	v_S^1	Tipo info.
<i>Delfín</i> _{R1}	-	-	-	Complementaria
<i>Florero</i> _{R2}	Todo <i>l</i>	$v_{P(2,l)}^1 < 0.65$	$v_{S(2,l)}^1 < 0.65$	Complementaria
<i>Lata</i> _{R1}	Todo <i>l</i>	$v_{P(3,l)}^1 < 0.65$	$v_{S(3,l)}^1 < 0.65$	Complementaria
<i>Botella refresco</i> _{R2}	Todo <i>l</i>	$v_{P(4,l)}^1 < 0.65$	$v_{S(4,l)}^1 < 0.65$	Complementaria
<i>Botella agua</i> _{R1}	<i>Botella refresco</i>	$v_{P(5,4)}^1 = 0.73$	$v_{S(5,2)}^1 = 0.59$	Confusa tipo 2
<i>Botella</i> _{R2}	<i>Lata</i>	$v_{P(6,5)}^1 = 0.58$	$v_{S(6,3)}^1 = 0.65$	Confusa tipo 1
<i>Florero</i> _{R1}	<i>Florero</i>	$v_{P(7,2)}^1 = 0.69$	$v_{S(7,2)}^1 = 1.00$	Coincidente
<i>Cono</i> _{R2}	Todo <i>l</i>	$v_{P(8,l)}^1 < 0.65$	$v_{S(8,l)}^1 < 0.65$	Complementaria

medios de las probabilidades obtenidas en el reconocimiento de objetos empleando los conceptos individuales y colectivos obtenidos por los robots del sistema.

En la gráfica de la figura 5.31, los errores de clasificación PCA del robot 1 ocurren

Tabla 5.27: Tipos de información detectada por el robot 2 por cada concepto individual propio y compartido por el robot 1.

Tipos de información detectada por el robot 2				
Objetos R2	Objetos R1	v_P^2	v_S^2	Tipo info.
<i>Florero</i> _{R2}	-	-	-	Complementaria
<i>Delfín</i> _{R1}	Todo <i>l</i>	$v_{P(2,l)}^2 < 0.65$	$v_{S(2,l)}^2 < 0.65$	Complementaria
<i>Botella refresco</i> _{R2}	Todo <i>l</i>	$v_{P(3,l)}^2 < 0.65$	$v_{S(3,l)}^2 < 0.65$	Complementaria
<i>Lata</i> _{R1}	Todo <i>l</i>	$v_{P(4,l)}^2 < 0.65$	$v_{S(4,l)}^2 < 0.65$	Complementaria
<i>Botella</i> _{R2}	Todo <i>l</i>	$v_{P(5,l)}^2 < 0.65$	$v_{S(5,l)}^2 < 0.65$	Confusa tipo 1
<i>Botella agua</i> _{R1}	<i>Botella refresco</i>	$v_{P(6,3)}^2 = 0.73$	$v_{S(6,1)}^2 = 0.59$	Confusa tipo 2
<i>Cono</i> _{R2}	Todo <i>l</i>	$v_{P(7,l)}^2 < 0.65$	$v_{S(7,l)}^2 < 0.65$	Complementaria
<i>Florero</i> _{R1}	<i>Florero</i>	$v_{P(8,1)}^2 = 0.69$	$v_{S(8,1)}^2 = 1.00$	Coincidente

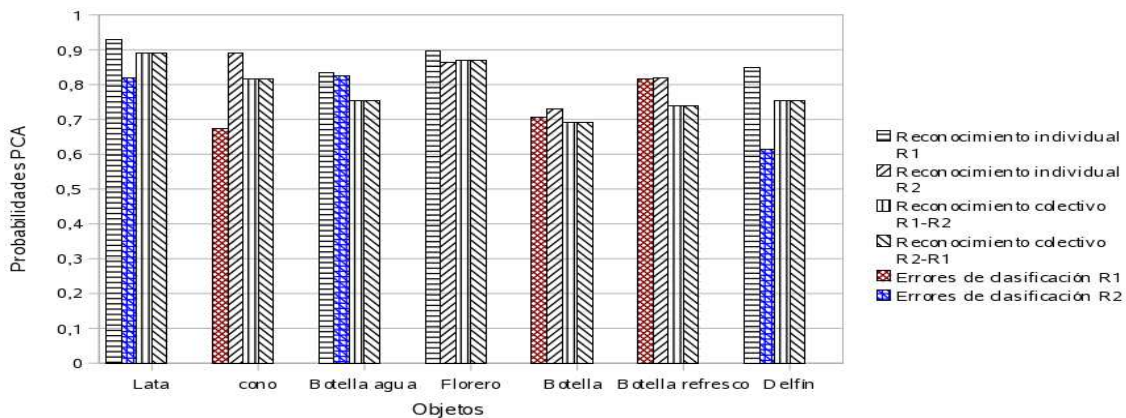


Figura 5.31: Probabilidades de clasificación PCA para el reconocimiento de objetos empleando tanto los conceptos individuales como los colectivos.

en los objetos *cono*, *botella* y *botella refresco*, los cuales son confundidos con los objetos *delfín*, *botella agua* y *botella agua*, respectivamente. Los errores de clasificación del robot 2 ocurren en los objetos de prueba *lata*, *botella agua*, y *delfín*, los cuales son confundidos con los objetos *botella*, *botella refresco* y *botella refresco*, respectivamente.

En la tabla 5.28 se muestran los porcentajes de clasificación promedio obtenidos en el reconocimiento de objetos empleando los conceptos individuales y los colectivos. En-




Figura 5.32: Probabilidades de clasificación SIFT para el reconocimiento de objetos. Ningún robot comete errores de clasificación.

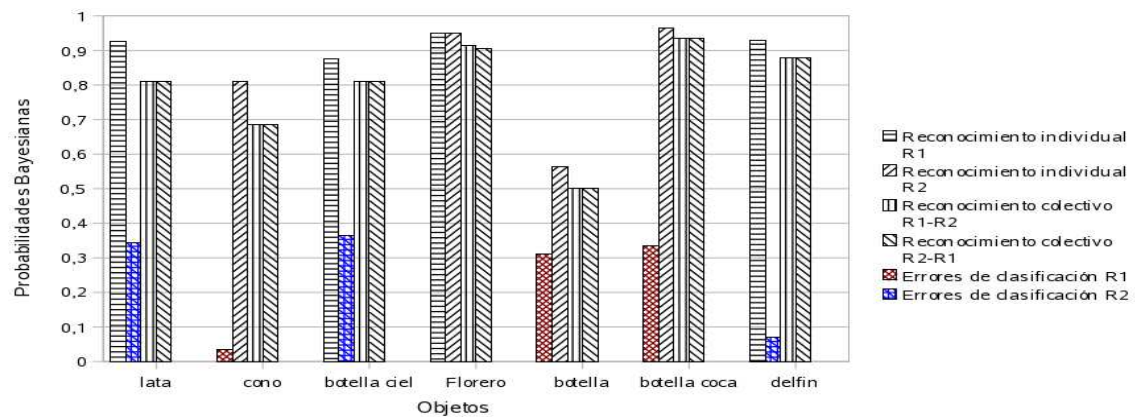


Figura 5.33: Probabilidades de clasificación empleando la fusión Bayesiana de las probabilidades de reconocimiento PCA y SIFT. Se observa que en promedio durante las cuatro pruebas de reconocimiento de objetos, los robots no fueron capaces de clasificar correctamente al bloque de imágenes correspondiente a la *botella*.

tre paréntesis se ilustran los porcentajes de clasificación promedio tomando en cuenta únicamente a los objetos conocidos por cada robot de forma individual.

Discusión y análisis. En el presente experimento los robots aprendieron en línea conceptos tanto individuales como colectivos. Posteriormente, se realizaron cuatro pruebas de reconocimiento de objetos empleando los conceptos adquiridos por los robots. Por los porcentajes de clasificación obtenidos en el experimento, se observa un incremento del

Tabla 5.28: Porcentajes de clasificación del reconocimiento de objetos empleando los conceptos individuales y los cooperativos adquiridos por los robots en el presente experimento.

Porcentajes de Clasificación				
	R1	R2	R1-R2	R2-R1
PCA	55.69 % (100.00 %)	49.98 % (94.82 %)	86.15 %	86.16 %
SIFT	48.32 % (86.23 %)	42.89 % (79.11 %)	87.84 %	87.84 %
Bayes	52.59 % (94.20 %)	51.68 % (81.54 %)	80.73 %	80.73 %

“conocimiento” en los conceptos colectivos respecto a los individuales.

Se observa por la gráfica de la figura 5.33 que los robots fueron capaces de clasificar la mayor parte de objetos de prueba empleando los conceptos colectivos con un porcentaje de clasificación superior al 80.00 %. Sin embargo, también se observa por las gráficas de probabilidades Bayesianas que los robots no pudieron clasificar correctamente al objeto *botella*, pues en promedio (empleando los conceptos colectivos), los robots clasificaron a dicho bloque de imágenes con una probabilidad de 0.5. Esto se debió principalmente a que ocurrieron errores en la segmentación del objeto tanto en el entrenamiento como en las pruebas. Lo anterior se aprecia al obtenerse una probabilidad promedio PCA de 0.69 en la gráfica de la figura 5.31, lo cual indica que la forma de los objetos de prueba son distintas a la forma de la silueta promedio del objeto *botella* calculada en el entrenamiento. Además, lo mismo ocurre para las características locales SIFT, pues se obtiene una probabilidad promedio de 0.63 para dicho objeto.

5.5. Discusión y comparación con otros trabajos

El método de aprendizaje cooperativo de conceptos empleando un sistema multi-robot fue comparado con los resultados de dos trabajos relacionados, desarrollados por Steels y Kaplan (2001) (ver sección 3.1 y O’Beirne y Schukat (2004) (ver sección 3.2.2).

El sistema multi-robot empleado en la presente tesis se compuso por dos robots, y

hasta donde sabemos es el único trabajo donde se aborda el problema en el que dos robots comparten conceptos aprendidos individualmente de forma autónoma y posteriormente realizan un análisis de los conceptos para formar un concepto colectivo. Este tipo de aprendizaje es conocido como aprendizaje cooperativo en sistemas multi-robot. En el trabajo presentado por Steels y Kaplan (2001), los autores utilizan un único robot para aprender objetos mediante la interacción humano-robot (ver sección 3.1). Por otro lado en el trabajo de O'Beirne y Schukat (2004), los autores emplean un sistema multi-robot conformado por dos robots en el cual combinan diferentes vistas u observaciones de un mismo objeto desde uno o más ángulos para el reconocimiento de objetos (ver sección 2.4.2).

En el trabajo propuesto por Steels y Kaplan (2001), los autores utilizan tres tipos de aprendizaje: supervisado, semi-supervisado y no-supervisado para el aprendizaje de objetos. El inconveniente en el trabajo de Steels y Kaplan (2001) es que al emplear aprendizaje no-supervisado para aprender de forma autónoma tres objetos distintos, el método propuesto por los autores no es capaz de detectar las relaciones existentes entre los distintos objetos de entrenamiento. A diferencia de ellos, en el presente trabajo se utilizó el aprendizaje no-supervisado para la adquisición de conceptos individuales, es decir, los robots no tienen conocimiento *a priori* del número o el tipo de objetos a aprender. El aprendizaje se realiza de manera autónoma e individual por los miembros del sistema multi-robot, y posteriormente se fusionan los conceptos aprendidos individualmente para construir los conceptos colectivos. Lo anterior es importante para robots que se desenvuelven en ambientes reales ya que bajo esas condiciones no siempre es factible que un robot conozca de antemano a todos los objetos que podrían encontrarse en dicho ambiente. En el trabajo propuesto por O'Beirne y Schukat (2004) los autores utilizan una base previa de objetos conocidos, y si durante el reconocimiento de objetos alguno de ellos resulta ser desconocido, entonces modelan al objeto en términos de su forma y apariencia para agregarlo a su base de objetos conocidos.

El número máximo de objetos aprendidos en el presente trabajo fue de 8 objetos, mientras que en el trabajo de Steels y Kaplan (2001) fue de 3, y en el trabajo de O'Beirne

y Schukat (2004) no se reporta el número máximo de objetos.

En este trabajo se realiza un análisis de los conceptos aprendidos por los robots del sistema para determinar la existencia de información coincidente, complementaria y contradictoria. Con ello se espera no sobre-representar a un mismo objeto en más de un concepto colectivo. Un análisis similar se reporta en el trabajo de O'Beirne y Schukat (2004), pero a diferencia de nosotros, para cualquier caso los autores consideran que un objeto desconocido es siempre un nuevo objeto. En el trabajo de Steels y Kaplan (2001) no se realiza ningún análisis con este propósito.

Finalmente, en ninguno de los dos trabajos con los que se comparó nuestro método se realiza algún tipo de comparación con otros trabajos similares.

En la figura 5.34 se presentan las gráficas que resumen las propiedades del sistemas mono-robot y multi-robot analizados. Las propiedades que se consideraron son: el tipo de comunicación, el tipo de ambiente en el que se realiza el entrenamiento, el tipo de aprendizaje, el tipo de entrenamiento, el tipo de características empleadas para formar los conceptos, el número de objetos aprendidos, y si se realiza o no un análisis y fusión de conceptos para evitar sobre-representar en más de un concepto a un mismo objeto. En la tabla 5.29 se indican los valores de los criterios considerados en la comparación. De acuerdo a estas gráficas, los valores más pequeños (1 y 2.5) representan baja adaptabilidad, en contraste con el valor más alto (4), el cual representa mayor adaptabilidad. Como lo muestran las gráficas, nuestro sistema es el que presenta mejor adaptabilidad y desempeño de acuerdo a la clasificación realizada.

5.6. Síntesis

Durante el desarrollo del presente trabajo se realizaron diversos experimentos tanto individuales como colectivos para el aprendizaje de conceptos empleando un sistema multi-robot. La idea básica fue que los robots aprendieran conceptos de manera individual y después compartieran dicho conocimiento entre los miembros del sistema multi-robot. Una vez compartido el conocimiento, cada robot realizó un análisis de los conceptos in-

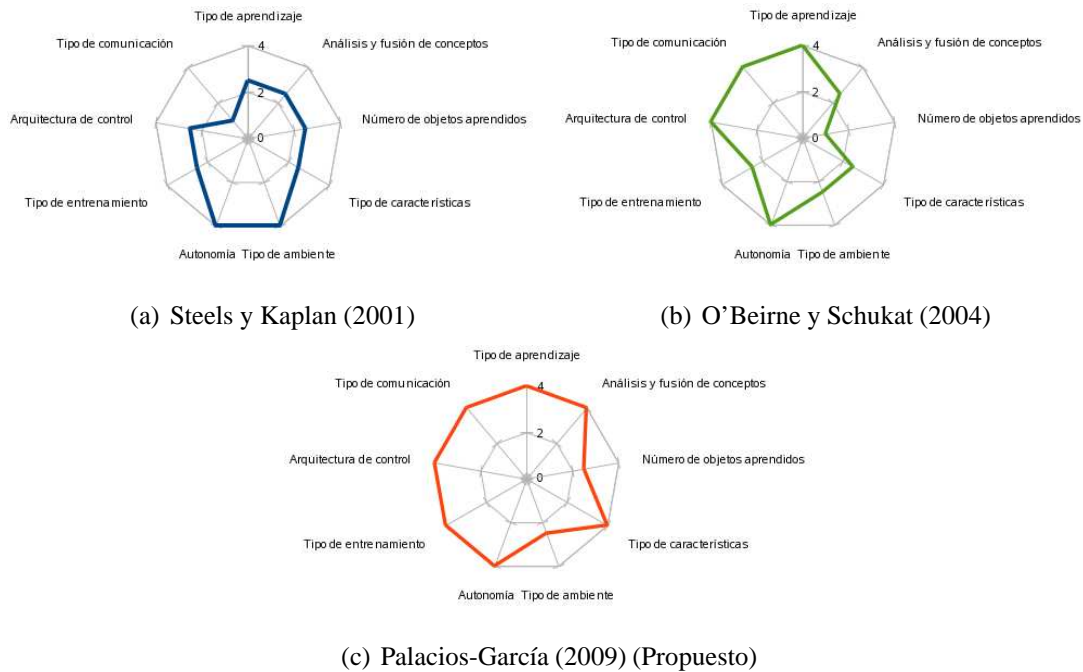


Figura 5.34: Comparación con trabajos relacionados. Los valores más pequeños (1 y 2.5) representan baja adaptabilidad, en contraste con el valor más alto (4), el cuál representa mayor adaptabilidad. Como lo muestran las gráficas, nuestro sistema es el que presenta mejor adaptabilidad de acuerdo a la clasificación realizada.

individuales propios y compartidos, para detectar la existencia de información coincidente, complementaria y confusa.

Los principales factores que influyeron para que en algunos de los experimentos los robots no extrajeran correctamente los conceptos individuales o no fueran capaces de reconocer adecuadamente los objetos de prueba fueron: los cambios en la iluminación, el brillo en los objetos y errores en los sensores (cámaras). Estos factores ocasionaron principalmente errores en la segmentación de los objetos, generando con ésto la obtención errónea de la forma de los mismos, y errores en la extracción de características locales SIFT.

Por los resultados de los experimentos realizados en el presente capítulo, se probó que al crear conceptos colectivos a partir de conceptos individuales, los robots enriquecen sus

Tabla 5.29: Criterios considerados en la comparación propuesta.

Valores de los criterios considerados en la comparación.			
Características	Valores		
	1	2.5	4
Autonomía	No-autónomos	Semi-autónomos	Autónomos
Tipo de comunicación	Sin comunicación	Indirecta	Directa
Arquitectura de control	-	Centralizada	Descentralizada
Tipo de ambiente	Estructurado	Semi-estructurado	No-estructurado
Tipo de aprendizaje	Supervisado	Semi-supervisado	No-supervisado
Tipo de entrenamiento	Fuera de línea	En línea	En línea y fuera de línea
Tipo de características	Locales	Globales	Combinación locales y globales
Numero de objetos aprendidos	No-reportado	Menos de 10 objetos	Arriba de 10 objetos
Análisis y fusión de conceptos	-	No-realizado	Realizado

representaciones individuales al adquirir la información observada por otro robot desde puntos de vista distintos o de nuevos objetos.

Se probó experimentalmente que al emplear características globales PCA y características locales SIFT éstas se complementan entre sí, lo que permite la distinción entre objetos distintos con forma similar, objetos con formas distintas y con texturas similares. También se probó que el modelar en probabilidades a las características globales PCA y locales SIFT para el reconocimiento de objetos, permite su fusión empleando la regla de Bayes, lo que permite obtener probabilidades de reconocimiento de objetos en las que se toma en cuenta la forma de los objetos y sus características locales.

Capítulo 6

Conclusiones y Perspectivas

6.1. Síntesis

El presente trabajo de tesis consistió en definir un método para el aprendizaje cooperativo de conceptos empleando un sistema multi-robot con dos miembros. Para que cada miembro del sistema multi-robot fuera capaz de aprender conceptos de forma individual y cooperativa, cada robot utilizó cuatro módulos:

1. **Módulo de entrenamiento individual:** En este módulo cada robot aprende conceptos individuales de los objetos observados por ellos mismos en el entrenamiento. Los conceptos individuales permiten representar a los objetos con dos tipos de características, las características de forma de los objetos (características globales PCA) y las características locales SIFT de los objetos o su apariencia.
2. **Módulo de comunicación:** En este módulo cada robot del sistema comparte con otro robot sus conceptos aprendidos individualmente empleando una red inalámbrica *WiFi*.
3. **Módulo de análisis y fusión de conceptos:** En este módulo se emplean los conceptos propios y compartidos entre los robots del sistema para la formación de conceptos colectivos. Para alcanzar la cooperación fue necesaria la compartición de

los conceptos individuales aprendidos por un robot, para posteriormente analizar los conceptos con la finalidad de enriquecerlos con la nueva información proporcionada por otro robot del sistema. En este módulo se identifican tres tipos de información: coincidente, complementaria y confusa entre los conceptos propios y compartidos por los robots del sistema. Dependiendo del tipo de información detectada es el tipo de fusión de conceptos a realizar por cada robot del sistema.

En este punto es importante mencionar que a pesar de que cada robot comparte con el otro sus conceptos aprendidos individualmente, cada robot del sistema realiza el análisis de los conceptos, y cada uno forma sus propios conceptos colectivos a partir de lo aprendido y lo compartido por el otro robot.

4. **Módulo de reconocimiento:** Este módulo permite a los robots reconocer objetos de prueba empleando tanto los conceptos aprendidos individualmente como los conceptos aprendidos cooperativamente. En este punto se realiza la fusión de las características globales PCA y las locales SIFT aplicando un esquema Bayesiano para conjuntar ambas evidencias.

Finalmente, por cada prueba de reconocimiento de objetos empleando los conceptos individuales y colectivos, se calcularon los porcentajes de clasificación para medir el desempeño de dichos conceptos.

6.2. Aportaciones

- La principal aportación de esta tesis fue el desarrollo de un método de aprendizaje cooperativo de conceptos para sistemas multi-robot basado en el análisis y fusión de conceptos aprendidos individualmente por los miembros del sistema multi-robot.
- **Esquemas de representación:** Se propusieron esquemas para la representación de objetos mediante una combinación de características globales PCA y locales SIFT.
- **Combinación de información global con local:** Se modelaron las características

locales SIFT y las características globales PCA en términos de probabilidades para su combinación empleando un esquema Bayesiano, lo cual permite que ambas características se complementen entre sí. Además, la combinación permitió realizar el reconocimiento de objetos tomando en cuenta ambos tipos de evidencias.

- **Mejora de conceptos:** Los conceptos colectivos adquiridos por los robots del sistema multi-robot son mejores respecto a los conceptos adquiridos por cada robot, debido a que se enriquecen al realizarse el análisis y fusión de conceptos compartidos. Esto se comprobó en la mejora en el reconocimiento de objetos, al aplicar los conceptos colectivos en comparación con los conceptos individuales.

Gracias a estos logros fue posible atacar los siguientes aspectos:

- **Aprendizaje en línea:** Los robots van aprendiendo conceptos de objetos como se les van presentando y a su vez, van construyendo sus conceptos colectivos empleando el concepto compartido por el otro robot del sistema. Posteriormente, los robots determinan qué tipo de información genera el concepto compartido respecto a sus conceptos actualmente conocidos, fusionan conceptos dependiendo del tipo de información detectada, y continúan aprendiendo objetos y compartiendo información entre sí.

El aprendizaje en línea resulta de vital importancia en robótica móvil para tareas en las que no es posible esperar a que los robots terminen de aprender para compartir su información. Un ejemplo de este tipo de tareas es la construcción simultánea de mapas por más de un robot, en donde si un robot se pierde en el ambiente ya no será posible recuperar su información. En cambio, si el aprendizaje se realiza en línea, aún cuando se haya perdido al robot, éste habrá enviado información al resto de robots del sistema que podría ser de vital importancia para la aplicación.

- **Reducción del tiempo de entrenamiento:** El tiempo necesario para realizar el entrenamiento individual se reduce en promedio a la mitad al realizar el aprendizaje

cooperativo de conceptos en línea. Esto se debe a que se divide el ambiente y la tarea entre los robots del sistema.

- **Experimentación con robots reales:** Se aplicó el método propuesto para el aprendizaje cooperativo de conceptos de un sistema multi-robot compuesto por dos robots reales.

6.3. Conclusiones y Perspectivas

En el presente trabajo se introdujo un método de aprendizaje cooperativo de conceptos para sistemas multi-robot. Algunos de las características principales del trabajo propuesto son:

- Los robots no conocen *a priori* el número de objetos que pueden observar durante el entrenamiento individual. Lo anterior involucra varios problemas ya que los robots necesitan decidir si un objeto nuevo o compartido corresponde a un concepto aprendido previamente o no.
- Los conceptos que representan a los distintos objetos de entrenamiento pueden aprenderse tanto en línea como fuera de línea, mientras los robots recorren el ambiente. Esta es una característica importante para construir robots autónomos.
- Se identifican tres casos posibles en los cuales pueden fusionarse los conceptos individuales y el cómo fusionarlos.

La detección de información coincidente permitió evitar sobre-representar a un mismo objeto en más de un concepto. Esto permitió enriquecer los conceptos adquiridos por los robots de manera individual.

La detección de información complementaria permitió detectar la existencia de objetos desconocidos durante el análisis de los conceptos aprendidos individualmente. Esto permite la integración de nuevos conceptos al robot miembro del sistema que desconoce al objeto, sin necesidad de que éste los aprenda de manera directa.

La detección de información confusa permitió fusionar información entre los miembros del sistema multi-robot cuando se presentan los dos casos siguientes: 1) cuando los objetos tienen diferente forma y características SIFT similares, y 2) cuando los objetos tienen la misma forma pero sus características SIFT son diferentes. El segundo caso es particularmente difícil de tratar debido a que cuando los objetos tienen la misma forma pero SIFT distintos pueden ocurrir dos situaciones, que se trate de objetos distintos o que se trate del mismo objeto cuyas caras son diferentes, y que al ser visto por los dos robots desde perspectivas distintas podría considerarse como objetos diferentes entre sí.

En general, el reconocimiento de objetos empleando los conceptos adquiridos cooperativamente tuvo un mejor desempeño que el reconocimiento de objetos empleando los conceptos adquiridos de forma individual, en términos de porcentajes de clasificación correcta. Esto se debió en gran parte a que la información cooperativa es más rica, pues provee mayor cantidad de características que amplían los conceptos y favorecen la clasificación.

Como trabajo futuro se propone el explorar los siguientes aspectos:

- **Esquemas de sustracción del fondo:** Integrar esquemas de sustracción del fondo para una segmentación de objetos robusta que permita aplicar el método propuesto a ambientes dinámicos. Por ejemplo una sustracción del fondo basada en la distancia a los objetos similar a la propuesta por Méndez-Polanco et al. (2009) .
- **Aprendizaje de clases de objetos:** Ampliar tanto los conceptos como el análisis de los mismos, para detectar posibles relaciones genéricas entre los objetos y así formar meta-clases que los agrupen. Para esto es necesario agregar más características que permitan representar y agrupar a los objetos en clases, estas características deberán contener información de la apariencia de los objetos, la forma, y la escala, entre otras, o bien combinaciones de ellas.
- **Planificación de trayectorias:** Planificar las trayectorias de recorrido de los robots para que de forma autónoma se repartan el ambiente para aprender los distintos

objetos contenidos en él en el menor tiempo posible.

- **Solución de confusiones:** Resolver automáticamente confusiones en las que los robots no identifican si se trata de un mismo objeto o de uno distinto. Para esto es necesario desarrollar algoritmos de búsqueda de vistas no capturadas por los robots, que les permitan autónomamente obtener mayor evidencia de dichos objetos, es decir, modelarlos, con lo cual se resuelven las confusiones y se evita “sobre-representar” a un objeto en más de un concepto dado. Al mismo tiempo, es necesario el aprendizaje o empleo de mapas del ambiente, que permitan a los robots detectar la ubicación y orientación de los distintos objetos aprendidos.
- **Fusión Bayesiana:** Mejorar el esquema empleado en la fusión Bayesiana de las probabilidades PCA y SIFT obtenidas en el reconocimiento, pesando dichas probabilidades dependiendo de cuál es la que permite una mayor discriminación en cada caso.

Bibliografía

- Asada M., Uchibe E., Noda S., Tawaratsumida S., y Hosoda K. (1994). Coordination of multiple behaviors acquired by vision-based reinforcement learning. *Proceedings of the International Conference on Intelligent Robots and Systems*, pp. 917–924.
- Awcock G. J. y Thomas R. (1995). *Applied Image Processing*. McGraw-Hill, Inc. Hightstown, NJ, USA.
- Balch T. y Parker L. E. editores (2002). *Robot Teams: from diversity to polymorphism*. A K Peters, Ltd., 63 South Avenue Natick, MA 01760.
- Corchado E., Abraham A., y Pedrycz W. editores (2008). *Hybrid Artificial Intelligence Systems*, cap. Applying Reinforcement Learning to Multi-robot Team Coordination, pp. 625–632. Springer Berlin/Heidelberg.
- Douillard B., Fox D., y Ramos F. (2000). A spatio-temporal probabilistic model for multi-sensor object recognition.
- Ekvall S., Jensfelt P., y Kragic D. (2006). Integrating active mobile robot object recognition and slam in natural environments. *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS '06)*, pp. 5792–5797.
- Ekvall S. y Kragic D. (2005). Receptive field cooccurrence histograms for object detection. *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS '05)*, pp. 84–89.

- Fernández F., Borrajo D., y Parker L. E. (2005). A reinforcement learning algorithm in cooperative multi-robot domains. *Journal of Intelligent and Robotic Systems*, 43:161–174.
- Floreano D. y Mattiussi C. (2008). *Bio-Inspired Artificial Intelligence: Theories, Methods, and Technologies*. MIT Press.
- Forsyth D. A. y Ponce J. (2003). *Computer Vision A Modern Approach*, cap. Tracking. Prentice Hall, Upper Saddle River, New Jersey 07458.
- Grimson W. E. L. (1990). *Object Recognition by Computer. The Role of Geometric Constraints*. MIT Press.
- Jiménez-Velasco M. G. (2006). *Diseño e implementación de un sistema multi-robot con capacidades de auto-ensamblado*. Tesis de maestría, en Ciencias Computacionales. Instituto Nacional de Astrofísica, Óptica y Electrónica, México.
- Johnson D. E. (2000). *Métodos Multivariados Aplicados al Análisis de Datos*. International Thomson Editores, séptima edición.
- Lisin D. A., Mattar M. A., Blaschko M. B., Benfield M. C., y Learned-Miller E. G. (2005). Combining local and global image features for object class recognition. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPRW'05)*, pp. 47–54.
- Liu J. y Wu J. (2001). *Multi-Agent Robotic Systems*. The CRC Press International Series on Computational Intelligence.
- Lowe D. G. (1999). Object recognition from local scale-invariant features. *International Conference on Computer Vision*, pp. 1150–1157.
- Lowe D. G. (2004). Distinctive image features from scale-invariant keypoints. *International Journal of Computer Vision*, pp. 91–110.



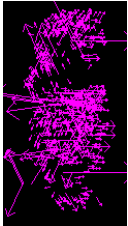
- Malagón-Borja J. L. S. (2005). *Detección de Peatones en Imágenes*. Tesis de maestría, en Ciencias Computacionales. Instituto Nacional de Astrofísica, Óptica y Electrónica, México.
- Matarić M. J. (1997). Reinforcement learning in the multi-robot domain. *Autonomous Robots*, 4(1):73–83.
- Mel B. W. (1997). Seemore: Combining color, shape, and texture histogramming in a neurally inspired approach to visual object recognition. *Neural Computation*, 9:777–804.
- Méndez-Polanco J. A., Muñoz-Meléndez A., y Morales E. F. (2009). People detection by a mobile robot using stereo vision in dynamic indoor environments. *The 8th Mexican International Conference on Artificial Intelligence (MICAI '09)*.
- Michaud F. y Vu M. (1999). Managing robot autonomy and interactivity using motives and visual communication. *Proceedings International Conference on Autonomous Agents*.
- Mitchell T. M. (1997). *Machine Learning*, cap. *Concept Learning, Bayesian Learning, Instance-Based Learning y Reinforcement Learning*. McGraw-Hill Science/Engineering/Math.
- Mitri S., Pervolz K., Surmann H., y Nuchter A. (2004). Fast color independent ball detection for mobile robots. *Proceedings of the IEEE International Conference Mechatronics and Robotics (MechRob '04)*, pp. 900–905.
- Montesano L. y Montano L. (2003). Identification of moving objects by a team of robots based on kinematic information. *Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS '03)*, 1:284–290.
- Murphey R. y Pardalos P. editores (2002). *Cooperative Control and Optimization*, cap. *Cooperative Control of Robot Formations*. Kluwer Academic Publishers.

- Murphy R. R. (2000). *Introduction to AI Robotics*, cap. Localization and Map Making, pp. 380–386. The MIT Press, Cambridge, Massachusetts. London, England.
- O’Beirne D. y Schukat M. (2004). Exploration and object recognition using cooperative robots. En Arabnia H. R. editores, *Proceedings of the International Conference on Imaging Science, Systems and Technology (CISST ’04)*, pp. 592–598. CSREA Press.
- Panait L. y Luke S. (2005). Cooperative multi-agent learning: The state of the art. *Autonomous Agents and Multi-Agent Systems*, 11(3)(3):387–434.
- Steels L. y Kaplan F. (2001). AIBO’s first words. The social learning of language and meaning. *Evolution of Communication*, 4(1):3–32.
- Thrun S., Burgard W., y Fox D. (2005). *Probabilistic Robotics*. Intelligent robotics and autonomous agents. The MIT Press. Cambridge, Massachusetts London, England.
- Vicente M. A., Reinoso O., Pérez C., Sabater J. A., y Azorín J. A. (2002). Reconocimiento de objetos 3D mediante análisis PCA. *Actas de las XXIII Jornadas de Automática. Universidad de La Laguna, Santa Cruz de Tenerife*.
- Viola P. y Jones M. (2004). Robust real-time object detection. *International Journal of Computer Vision*, 57(2):137–154.
- Witkin A. P. (1983). Scale-space filtering. *International Joint Conference on Artificial Intelligence*, pp. 1019–1022.
- Yang E. y Gu D. (2004). Multiagent reinforcement learning for multi-robot systems: A survey. Reporte tecnico, CSM-404, University of Essex, Department of Computer Science.
- Ye Y. y Tsotsos J. K. (1996). On the collaborative object search team: A formulation. En *ECAI’96 Workshop LDAIS, Budapest, Hungary*, pp. 94–116.

Apéndice A. Ejemplos de conceptos aprendidos por los robots

A continuación presentamos un ejemplo de un concepto aprendido que representa al objeto *florero*. En la tabla se ilustran algunos de los valores que corresponden al concepto del objeto florero. Los conceptos se forman por dos partes: la parte que indica la forma del objeto (parte PCA del concepto) y la parte que indica las características locales del objeto (parte SIFT del concepto).

Tabla A.1. Ejemplo del concepto aprendido por un robot para el objeto florero. .

Objeto	Características extraídas	Concepto (Representación interna del robot)
 <p data-bbox="277 1581 375 1608">Objeto 1</p>	 <p data-bbox="432 1619 703 1787">Características SIFT del objeto detectadas en las diferentes vistas del mismo.</p>	 <p data-bbox="794 1581 1278 1659">Parte SIFT del concepto, contiene los puntos característicos del objeto.</p> <p data-bbox="730 1693 1342 1749">Número total de SIFT distintos detectados en el objeto: 982.</p> <p data-bbox="730 1756 1342 1890"> <code>SIFT = 0</code> <code>x = 41, 145207, y = 97, 881659, a = 0, 000000, b = 0, 000000, c = 0, 000000, scl = 20, 364702, ori = 2, 842109, d = 128, type = 1, category = 0, img_p.t.x = 41, 145207, img_p.t.y = 97, 881659, mdl_p.t.x = 0, 000000, mdl_p.t.y = 0, 000000.</code> </p>

