Universidad Autónoma del Estado de Morelos

Instituto de Investigación en Ciencias Básicas y Aplicadas

Centro de Investigación en Ciencias

Modelado de una arquitectura de modelos internos para la generación de esquemas sensorimotrices

T E S I S

QUE PARA OBTENER EL GRADO DE:
DOCTOR EN CIENCIAS

PRESENTA:
Lic. Esaú Eliezer Escobar Juárez

DIRECTOR DE TESIS:
Dr. Bruno Lara Guzmán (CInC, UAEM)

Cuernavaca, Morelos Marzo 2017

Índice general

CAPÍTULO

1. Introducción **1**
- 1.1. Motivación . . . 4
- 1.2. Hipótesis . . . 5
- 1.3. Objetivo . . . 5
  - 1.3.1. Objetivos específicos . . . 6
- 1.4. Estructura de la tesis . . . 6
- 1.5. Publicaciones . . . 7

2. Robótica Cognitiva **9**
- 2.1. Cognitivismo . . . 10
- 2.2. Limitaciones de la GOFAI . . . 11
- 2.3. Cognición corporizada . . . 13
- 2.4. Modelos Internos . . . 16
  - 2.4.1. Descripción formal . . . 18
  - 2.4.2. Modelos internos en la robótica . . . 21

3. Herramientas computacionales **27**
- 3.1. Inspiración Biológica . . . 28
- 3.2. Mapas auto-organizados . . . 29
  - 3.2.1. Aprendizaje SOM . . . 31
  - 3.2.2. Calidad del SOM . . . 34
  - 3.2.3. Características de los SOM . . . 36
- 3.3. Asociación entre mapas . . . 37

4. SOIMA Básico **39**
- 4.1. Entrenamiento General . . . 39
- 4.2. Modelos Internos y SOIMA . . . 40
- 4.3. Propiedades SOIMA . . . 42
- 4.4. Control de movimientos sacádicos para una cámara PTZ 44
  - 4.4.1. Plataforma y entorno experimental . . . 45
  - 4.4.2. Estructura SOIMA . . . 45

4.4.3. Entrenamiento de la red SOIMA 47
4.4.4. Experimentos y resultados 54
4.5. Control sacádico para un Robot humanoide NAO . . . 59
4.5.1. Entrenamiento de la red SOIMA 62
4.5.2. Experimentos y resultados 67

5. Casos de estudio **75**
5.1. Coordinación ojo-mano en el robot NAO 75
5.1.1. Plataforma y entorno experimental 78
5.1.2. Entrenamiento 79
5.1.3. Resultados 82
5.2. Caracterización de trayectorias 86
5.2.1. Plataforma y entorno experimental 87
5.2.2. Entrenamiento de SOIMA 87
5.2.3. Experimentos y Resultados 90
5.3. SOIMA Dinámico 94
5.3.1. SOM Dinámicos (DSOM) 96
5.3.2. Plataforma y entorno experimental 98
5.3.3. Entrenamiento de DSOIMA 98
5.3.4. Experimentos y Resultados 100

6. Conclusiones **105**

Índice de figuras

2.1. Esquema del modelo directo. 18
2.2. Esquema del modelo inverso. 19

3.1. Estructura básica de un mapa auto-organizado (SOM). 32
3.2. Estado del SOM durante el entrenamiento 35

4.1. Estructura básica SOIMA. 40
4.2. Asociación multimodal en el esquema básico SOIMA. 41
4.3. Entorno experimental del control sacadico 45
4.4. Control sacádico 46
4.5. Esquema SOIMA utilizado en el control sacadico 47
4.6. Imagen de rasgos sobresalientes 49
4.7. Preprocesamiento de la imagen de entrada 50
4.8. Rangos de movimiento Pan-Tilt 51
4.9. Distribución del estímulo visual 52
4.10. Fragmento del mapa S_t entrenado 53
4.11. Uso de SOIMA para el control sacádico 55
4.12. Error del estímulo al centro de la imagen 56
4.13. Movimientos sacádicos antes y después del aprendizaje en linea 57
4.14. Ejemplo típico de ejecución 58
4.15. Primer movimiento sacádico de aproximación 59
4.16. Segundo movimiento sacádico de afinación 60
4.17. Robots Humanoides NAO v5 61
4.18. Entorno experimental en el simulador Webots 62
4.19. Estructura SOIMA para el control sacádico NAO 63
4.20. Preprocesamiento de la imagen de entrada 64
4.21. Distribución del estímulo visual NAO 64
4.22. Distorsión durante el entrenamiento de los mapas 65
4.23. Contribución del aprendizaje al desempeño 67
4.24. Trayectoria del estímulo antes y después del aprendizaje en linea 68
4.25. Ejemplo de predicción típica. 69
4.26. Desempeño de la predicción 70
4.27. Ejecución de movimientos sacádicos. 71

4.28. Desempeño de la ejecución 72
4.29. Trayectoria del estímulo 73

5.1. Esquema sensorimotriz para la EHC 76
5.2. Estructura SOIMA para la EHC 77
5.3. Entorno de la coordinación visuo-motriz 78
5.4. Distorsión SOM para la HEC 81
5.5. Cobertura de los SOM en la EHC 82
5.6. Uso de SOIMA durante el entrenamiento 83
5.7. Incremento en la detección del marcador 84
5.8. Espacio de detección de la mano por la HEC 84
5.9. Fases en un ejemplo para la tarea de señalización 86
5.10. Estructura SOIMA para la caracterización de trayectorias . . . 88
5.11. Plano de movimiento de la mano izquierda 89
5.12. Distorsión de los SOM para la caracterización de trayectorias . 90
5.13. Recreación de una trayectoria horizontal 91
5.14. Recreación de una trayectoria vertical 92
5.15. Recreación de trayectorias en el MMR_{path} 92
5.16. Trayectorias horizontales con su activación en el MMR 93
5.17. Trayectorias verticales y su activación en el MMR 94
5.18. Trayectorias en diagonal con pendiente positiva 95
5.19. Trayectorias en diagonal con pendiente negativa 96
5.20. Estructura DSOIMA para la HEC 97
5.21. Distorsión de los DSOM 101
5.22. Cobertura de los DSOM 102
5.23. Recuperación de la distorsión después de una lesión 103
5.24. Ajuste del DSOM *Head* a la distribución con perturbación . . 104

RESUMEN

Modelado de una arquitectura de modelos internos para la generación de esquemas sensorimotrices

Lic. Esaú Eliezer Escobar Juárez

El trabajo de investigación reportado en esta tesis, esta enmarcado en la nueva inteligencia artificial, también conocida como robótica cognitiva. Está busca investigar, implementar y corroborar teorías y modelos de la cognición, propuestos por las ciencias cognitivas en general. Para lograr esto, se proponen modelos computacionales que usan agentes artificiales como plataformas experimentales.

Este trabajo se centra en el estudio de modelos internos, modelos propuestos por las ciencias cognitivas como posibles mecanismos para la codificación de habilidades cognitivas fundamentales tales como la simulación, la predicción y la integración multimodal. En concreto, se propone la Arquitectura de Modelos Internos Auto-Organizados (SOIMA). Está es una arquitectura cognitiva computacional basada en mapas auto-organizados y aprendizaje hebbiano. Dentro de las características más importantes de la SOIMA encontramos que provee un sustrato unificado de integración sensorimotriz y herramientas flexibles y escalables para modelar la cognición. En la tesis, se discute el diseño y las características de la arquitectura y se proporcionan resultados empíricos en un agente artificial que demuestran los beneficios y potencialidades del concepto SOIMA. Como casos de estudio se han modelado e implementado un sistema de control de movimientos sacádicos para una cámara y para el robot humanoide NAO, además, un esquema de coordinación ojo-mano, la caracterización de trayectorias de la mano del agente y una variante de la arquitectura utilizando mapas auto-organizados dinámicos. Los resultados obtenidos validan a la SOIMA como una arquitectura escalable, modular y que supera algunas de las deficiencias de otros modelos actuales.

Capítulo 1

Introducción

Desde hace tiempo, los robots han desempeñado el papel de maquinas veloces, poderosas y precisas en los procesos de manufactura automatizada. Así mismo se han estado realizado grandes esfuerzos e investigaciones para ampliar el rango de aplicaciones de los robots.

Uno de los grandes desafíos ha sido el de adoptar agentes artificiales en dominios diferentes de aplicación mas allá de las fabricas. Por ejemplo podrían utilizarse en la agricultura, en labores de limpieza, para tareas como la vigilancia, la inspección y el mantenimiento en ambientes peligrosos, entre otras. También, pueden ser usados para el entretenimiento, el cuidado de personas de la tercera edad o con alguna capacidad mental diferente y la rehabilitación.

Existen múltiples razones por las cuales puede ser benéfico adoptar robots en esos ámbitos. Entre ellas podemos mencionar a los robots ayudantes que, en lugares peligrosos, pueden reducir el riesgo de lesiones humanas. También, podemos mencionar los beneficios que pueden traer en el campo educativo, en el cual cumplirían la función de provocar el aprendizaje con la metodología de la experimentación (Vivet, et al., 1990).

Sin embargo, varios factores están frenando la propagación de robots fuera de los laboratorios y fabricas. Desde un punto de vista técnico, hay aun varios retos abiertos en la implementación de habilidades motrices y cognitivas en los agentes artificiales. De hecho, una diferencia sustancial con los sistemas biológicos, es que en el estado del arte, los robots, aún no son apropiadamente capaces de aprender, adaptarse, reaccionar a circunstancias inesperadas, exhibir un nivel acertado de inteligencia y autónomamente y sin peligro operar en entornos inciertos y sin restricciones.

Con el fin de lidiar con estos problemas, los roboticistas han ampliado los limites de su investigación hacia algunas de las diferentes áreas que integran las ciencias cognitivas, como son: la psicología, las neurociencias e incluso la filosofía. Consecuentemente, han surgido varios campos de investigación en la robótica, entre los que se encuentra la *robótica cognitiva*. La robótica cognitiva

intenta dotar de comportamiento inteligente[1] a agentes artificiales utilizando modelos de la cognición (Clark et al., 1999; Levesque et al., 2010). Dichos modelos de la cognición, pueden tomar inspiración de las ciencias cognitivas. Esto permite, por una parte, proveer a los agentes con habilidades cognitivas básicas (Pfeifer et al., 2001), mientras que, por otra parte, los robots pueden ser usados como objeto de experimentación para los modelos en los campos mencionados y para probar estos modelos bajo condiciones controladas (Dautenhahn, 2003).

En el contexto de la robótica cognitiva, tiene gran relevancia la cognición corporizada, la cual enfatiza que un agente necesita de un cuerpo para desarrollar cognición (Pezzulo, et al., 2011). Es por esto que los robots cobran importancia en el estudio y desarrollo de capacidades cognitivas, pues actúan como intermediarios e integradores del mundo en la cognición (Vernon, et al., 2010).

Otro aspecto importante a tener en cuenta en el contexto de la robótica cognitiva, es el estudio de la cognición desde la perspectiva de las capacidades modales de los agentes. En un agente existen dos clases principales de modalidades: las sensoriales y las motrices. Las modalidades sensoriales se conforman de los datos provenientes de los distintos sensores distribuidos en el cuerpo del agente. Dichas modalidades se encargan de proveer la información necesaria acerca del estado del entorno y del propio cuerpo. Las modalidades motrices, por otra parte, se relacionan con los diferentes actuadores en el cuerpo del agente. Sobre estas modalidades es que toman efecto los comandos motrices generados por el agente para completar sus objetivos.

La exploración de estas capacidades modales se hace bajo el enfoque de la cognición cimentada (Barsalou, 2008). En esta se remarca la importancia de la interacción del cuerpo del agente con el entorno para la estructuración y surgimiento de habilidades cognitivas, a través de las capacidades sensorimotrices especificas del agente. Esto guarda una estrecha relación con el concepto de enacción, introducido en el trabajo de Varela, et al. (1991), el cual se refiere a que la manera en que se experimenta el mundo esta determinada por las interacciones entre el cuerpo y el entorno. Lo anterior apunta a que las características corporales tienen gran influencia en los procesos cognitivos y al mismo tiempo son constructoras de la coordinación sensorimotriz.

[1] Dado que esta más allá del alcance de esta tesis, no queremos realizar una discusión de cómo debe ser definida la inteligencia. Sin embargo, cuando hablamos de un "agente inteligente", tenemos en mente a un agente que puede actuar de manera autónoma en su nicho ecológico específico, que tiene un repertorio no trivial de acciones para elegir y es capaz de modificar ese ambiente para su supervivencia.

En principio, esto puede parecer una relación uni-direccional de entrada-salida (los datos sensoriales entran, los comandos motrices salen), sin embargo, el razonamiento teórico y la evidencia experimental en las ciencias cognitivas han mostrado que el procesamiento sensorimotriz no sucede de esa forma. Mientras que la relación uni-direccional entrada-salida entre los datos sensoriales y motrices puede ser una manera adecuada de tratar varios problemas de control motriz, en otras áreas, como la percepción y la cognición, se requiere de un enfoque diferente. En dichas áreas, la clara distinción entre la percepción y la acción es reemplazada por una visión integrada y dinámica del procesamiento sensorimotriz.

Entre otros, un estudio llevado a cabo por Held et al. (1963) ilustra la necesidad de un enfoque integrado: en su experimento, parejas de gatos de dos semanas de nacidos fueron enganchados a un carrusel. A uno de los individuos (miembro activo) de cada par de gatos se le permitió caminar y mover el carrusel, mientras que el otro individuo (miembro pasivo) permanecía suspendido sin contacto con el suelo. De esta manera, el miembro pasivo estaba sujeto a los mismos movimientos que el miembro activo, pero sin controlar su realización. Ambos gatos recibieron la misma estimulación visual sobre un largo periodo de tiempo. Fuera del carrusel los gatos crecieron en completa oscuridad. En pruebas subsecuentes se mostró que el miembro activo desarrolló una coordinación y visión normal, mientras el miembro pasivo sufrió de severas deficiencias en la percepción de profundidad y la coordinación sensorimotriz patas-ojos.

El trabajo de Suzuki, et al. (2005) recreó el experimento de Held y Hein (1963) pero utilizando agentes artificiales en lugar de agentes biológicos. En este experimento se encontró que los agentes evolucionados de forma activa, es decir, aquellos que podían controlar sus movimientos, tuvieron un mejor desempeño que los agentes pasivos, a los cuales se les restringió el control de sus movimientos.

Estos experimentos sugieren que el movimiento auto-realizado es necesario para el desarrollo de habilidades sensoriales y coordinación sensorimotriz normal. No es suficiente para un agente obtener información sensorial pasivamente, sino que es necesario que el organismo genere los comandos motrices, se mueva y observe los efectos sensoriales resultantes. De esta manera, la extracción de regularidades de las distintas modalidades sensoriales y motrices, así como el aprendizaje de las relaciones entre dichas modalidades, es lo que integra los *esquemas sensorimotrices* (O'Regan et al., 2001). Estos esquemas dan lugar a la percepción (Noë, 2004).

Es importante considerar que aún cuando es cierto que existe una brecha

considerable entre el comportamiento inteligente de un lado y el procesamiento sensorimotriz del otro. Esta brecha se va achicando a través del progreso de la investigación en el campo (Di Paolo, et al., 2014; Seth, 2014). Los investigadores tratan de entender como pueden ser aprendidos los esquemas sensorimotrices, y como pueden ser usados para guiar el comportamiento y facilitar la percepción.

Por otro lado, uno de los esquemas concebidos en la teoría de control (Atkeson, 1989; Jordan et al., 1992) y que han mostrado afinidad en resultados de estudios de neurociencias (Jeannerod, 1995; Wolpert, et al., 1998, 2001) son los *modelos internos*. Un modelo interno es un sistema que codifica el comportamiento de un proceso natural y describe las relaciones entre las acciones y sus consecuencias (Wolpert, et al., 1995). Estos modelos, proveen a los agentes con las capacidades de anticipación, predicción y planeación motriz mediante el uso de simulaciones internas (Schillaci, et al., 2012b).

Sobre la base de los modelos internos se puede construir la integración sensorimotriz, ya que estos fusionan de manera natural la información motriz y la sensorial y crean una representación multimodal (Wolpert et al., 1998).

Como mencionan Miall et al. (1996), principalmente podemos clasificar a los modelos internos en dos grupos: El primero, los *modelos inversos o controladores*, que proveen la acción necesaria para llevar al sistema a un estado deseado. El segundo grupo, los *modelos directos o predictores*, los cuales proporcionan la predicción del estado en que se encontrará el sistema después de llevar a cabo una acción partiendo de la situación actual.

1.1. Motivación

Considerando la importancia de la coordinación sensorimotriz adaptativa e integrada, esta tesis propone un modelo computacional que permite la construcción de esquemas sensorimotrices utilizando modelos internos.

Creemos que para que los robots puedan alcanzar capacidades avanzadas que les permitan un desempeño autónomo, es primeramente necesario enfocarse en la construcción de esquemas sensorimotrices de bajo nivel.

Para ello, es importante proveer a los agentes artificiales con la capacidad para construir sus propios esquemas sensorimotrices de bajo nivel. Y que estos esquemas estén cimentados en la experiencia adquirida por medio de la interacción del cuerpo del agente con su entorno.

Estamos convencidos de que este conocimiento sensorimotriz se crea en es-

tructuras de integración multimodal que codifican la relación subyacente entre las diferentes modalidades (sensoriales o motrices). El conocimiento de las diferentes modalidades, así como su integración, se debe descubrir y capturar sobre las regularidades del flujo de información sensorial. Este flujo de información está limitado y a la vez enriquecido, por las capacidades sensoriales únicas del agente que a su vez se vuelven las únicas relevantes a él mismo. Este descubrimiento, que comienza con el simple balbuceo motriz[2], culmina con la construcción de habilidades motrices precisas.

Es por todo esto, que es importante proponer una implementación computacional de una arquitectura para la codificación de esquemas sensorimotrices en agentes artificiales. Así mismo creemos importante analizar los alcances de dicha arquitectura a través de algunos casos de estudio.

El presente trabajo de investigación surge de las siguientes preguntas de investigación:

1. ¿La creación de asociaciones multimodales puede servir de base para la construcción de esquemas sensorimotrices en un agente?.

2. ¿Es posible la creación de una arquitectura que permita la escalabilidad de capacidades sensorimotrices mediante la integración de diferentes esquemas sensorimotrices como módulos constructores?.

3. ¿Es posible construir un mecanismo que incorpore los cambios en el esquema sensorimotriz debido a factores externos o internos, proveyendo al agente con la capacidad de adaptarse en-linea?.

1.2. Hipótesis

La hipótesis de la investigación de esta tesis es:

> *Una arquitectura basada en mapas auto-organizados y aprendizaje hebbiano permitirá a un agente artificial adquirir y utilizar modelos internos mediante la codificación de esquemas sensorimotrices.*

[2] El balbuceo motriz se refiere al proceso de aprender la relación de los movimientos musculares específicos con sus consecuencias sensoriales mediante la exploración aleatoria del espacio motor. Se encuentra basado en el mecanismo de exploración motriz de los infantes (Meltzoff et al., 1997)

1.3. Objetivo

En esta tesis el objetivo principal es el diseño e implementación de una arquitectura de aprendizaje en el contexto de la robótica cognitiva, que codifique y explote esquemas sensorimotrices en un agente autónomo artificial.

1.3.1. Objetivos específicos

Para lograr el objetivo principal se tiene los siguientes objetivos específicos:

- Diseño e implementación de una arquitectura para la representación de asociaciones multimodales que puedan servir de base para la construcción de esquemas sensorimotrices en un agente.
- Construcción de una organización jerárquica de esquemas sensorimotrices.
- Proponer un mecanismo para la incorporación de cambios en el esquema sensorimotriz debido a factores externos o internos al agente (adaptación en-linea).

1.4. Estructura de la tesis

En esta sección se esboza una guía general del contenido de cada uno de los siguientes capítulos.

En el capítulo 2 se presentan los conceptos fundamentales de la robotica cognitiva. Así como una breve revisión sobre el cognitivismo, el cual es una de las ideas precursoras de la robótica cognitiva y sobre la cual se detona el origen de dicho paradigma. También, se presenta una revisión conceptual de los modelos internos y el rol que desempeñan en el desarrollo de la cognición. Estos conceptos conforman las ideas fundamentales sobre las cuales se sustenta el presente trabajo de tesis.

El capítulo 3 describe los métodos computacionales sobre los que se elabora la arquitectura de modelos internos auto-organizados. La presentación en este capítulo se concentra en las partes fundamentales de cada método.

El capítulo 4 describe la estructura básica de la arquitectura y su modelación.

En el capítulo 5 se presentan algunos casos de estudio relevantes, con la finalidad de mostrar la funcionalidad de la arquitectura propuesta y esbozar

los alcances de la misma. Así mismo se presentan y analizan los resultados en los que se muestra la creación de esquemas de integración sensorimotriz.

Las conclusiones se presentan en el capítulo 6 en donde se resumen los principales logros alcanzados, así como algunas de las fortalezas y contribuciones de la arquitectura en el desarrollo de esquemas sensorimotrices.

1.5. Publicaciones

Revistas

- **Escobar, E.**, Schillaci, G., Hermosillo, J., y Lara, B. A self-organized internal models architecture for coding sensory-motor schemes. *Frontiers in Robotics and AI*, 3(22), 2016

- Gaona, W., **Escobar, E.**, Hermosillo, J., y Lara, B. Anticipation by multi-modal association through an artificial mental imagery process. *Connection Science*, 27(1):68–88, 2015

- Gaona, W., **Escobar, E.**, Hermosillo, J., y Lara, B. Adquisición de conceptos espaciales en un agente autónomo artificial a través de simulaciones internas. *Nova scientia*, 7(14):127–161, 2015

- Castillo, D., **Escobar, E.**, Hermosillo, J., y Lara, B. Modelado de un sistema de neuronas espejo en un agente autónomo artificial. *N*ova Scientia, 5 (2), 10:51-72, 2013

Congresos

- **Escobar, E.**, Hermosillo, J., y Lara, B. Self-body mapping in mobile robots using vision and forward models. In *Electronics, Robotics and Automotive Mechanics Conference (CERMA), 2012 IEEE Ninth*, pages 72–77. IEEE, 2012

- Koenigsberger, G., Lara, B., **Escobar, E.**, Harrington, M., Avena-Koenigsberger, A., y Moreno, E. On the orbital phase dependence of spicas line-profile variability. In *Magnetism and Variability in O stars*, 2014

- **Escobar, E.**, Gaona, W., y Lara, B. Modelado de un controlador sacádico a través de una arquitectura de integración multimodal. In *1er. Congreso de Psicología y Transdisciplinariedad*, Oaxtepec, Morelos, Mayo 2015

- **Escobar, E.** y Lara, B. Modelado de atención visual usando agentes autónomos a través del uso de modelos internos. In *5to Congreso de la Licenciatura y Posgrado en Ciencias*. CIICAp, de la Universidad Autónoma del Estado de Morelos, 2013

Capítulo 2

Robótica Cognitiva

La "robótica cognitiva" es un nuevo paradigma dentro de la Inteligencia Artificial. Surge como una respuesta al cognitivismo (Sección 2.1) y las limitaciones de la Inteligencia Artificial tradicional (Sección 2.2). La robótica cognitiva busca dotar a un agente artificial de comportamiento inteligente basándose en las teorías y modelos de la cognición. Ésta se enfoca principalmente en retomar teorías y modelos de la cognición, concebidos mediante estudios de neurociencias o de psicología, e implementarlos en agentes artificiales. Esto tiene como objetivo por una parte estudiar las implicaciones de estos modelos bajo condiciones controladas y por otra parte proveer a los agentes con habilidades cognitivas básicas (Pfeifer y Scheier, 2001).

Un referente de investigación en la robótica cognitiva es el estudio de la cognición desde la perspectiva de las capacidades sensoriales y motrices de los agentes. La exploración de estas capacidades se hace bajo el enfoque de la cognición cimentada (Barsalou, 2008). En esta se remarca la importancia de la interacción del cuerpo del agente, haciendo uso de sus capacidades sensorimotrices especificas, en el entorno para la estructuración y surgimiento de habilidades cognitivas (Wilson, 2002).

Esta tesis esta basada en la idea de que la cognición esta cimentada en la experiencia corporal del agente con el mundo. En consecuencia, los modelos cognitivos serán implementados en agentes artificiales que estén vinculados a sus características físicas y su interacción con el entorno.

Es por tanto pertinente aclarar las bases de la robótica cognitiva, es decir, la necesidad de corporización de un agente para hablar de un agente cognitivo (Sección 2.3). Por otra parte, también es necesario mencionar los modelos, fundamentales en esta tesis, sobre los cuales se basa la adquisición de esquemas sensorimotrices en un agente (Sección 2.4).

2.1. Cognitivismo

Hasta hace unas décadas, la corriente principal de investigación en inteligencia artificial fue la lógica y la resolución de problemas. Los investigadores enfocaban sus esfuerzos en intentar reproducir la inteligencia humana en sistemas artificiales, basado en el supuesto que la cognición humana era un complejo proceso de manipulación de representaciones del mundo externo.

En este ámbito, la investigación en inteligencia artificial estuvo influenciada por las teorías filosóficas respecto a la separación del cuerpo y de la mente. Este dualismo forma las bases de la hipótesis del "Cognitivismo". El supuesto central del enfoque cognitivista es la "Hipótesis del Sistema de Símbolos Físicos", la cual establece que "un sistema de símbolos físicos tiene los medios necesarios y suficientes para exhibir acciones inteligentes" (Newell et al., 1976). En este sentido, la cognición esta definida como el computo sobre representaciones simbólicas del mundo para producir respuestas lógicas, así como una maquina de procesamiento de información lo haría (Hoffmann, 2014). Crear representaciones simbólicas se refiere al proceso de abstraer la información del entorno convirtiéndola en símbolos.

En tanto que la necesidad de algún tipo de representación es normalmente aceptada, el enfoque cognitivista implica que realmente se elaboran representaciones en el cerebro en forma de un código simbólico.

En 1956, McCarthy, Minsky, Shannon and Nat Rochester sostuvieron una conferencia en Dartmouth la cual se considera haber dado a luz a la inteligencia artificial (McCarthy, et al., 2006). El cognitivismo fue el principal paradigma en sus discusiones sobre la cognición humana y su reproducción en maquinas artificiales (Miller, 2003). Por algunas décadas, el enfoque cognitivista dominó la investigación en inteligencia artificial e influenció la manera en que fueron diseñados los modelos computacionales de la inteligencia humana.

Una característica importante del planteamiento cognitivista es el fuerte énfasis sobre la construcción de representaciones. Esto implica que un agente tiene que construir una representación de los datos sensoriales que recibe de sus sensores. Por ejemplo, en la teoría de la visión de Marr (Marr, 1982) el objetivo de la visión es crear una representación del mundo tridimensional alrededor del agente desde el patrón de luz detectada por sus sensores visuales. En este proceso, los objetos más importantes son reconocidos mientras la información no relevante es descartada. Después un procesador central usa la representación del mundo para resolver el problema. Finalmente, este procesamiento genera los comandos motrices que son enviados a los actuadores. La perspectiva cogni-

tivista sigue un esquema de 3 etapas: entrada-procesamiento-salida, las cuales son completamente separables y entendibles en si mismas sin ningún tipo de referencia al entorno del agente.

La parte de la inteligencia artificial que adoptó el paradigma cognitivista se conoce como "GOFAI" (por sus siglas en ingles *Good Old-Fashioned Artificial Intelligence*) (Haugeland, 1985). Este enfoque de la inteligencia artificial, fue muy exitoso en los dominios formales donde el estado del mundo es discreto y directamente accesible. En estos dominios las técnicas estándar de la inteligencia artificial como la representación de conocimiento y la búsqueda pueden ser aplicadas adecuadamente. Mientras los esfuerzos principales se concentraron en desarrollar un sistema de "pensamiento" abstracto, al pasar al mundo real, se debió establecer una relación entre la realidad dinámica, continua y parcialmente accesible y la representación interna del mundo. Es decir, que la realidad tenia que ser sensada y mapeada al modelo del mundo interno, en el que se realizaba el "pensamiento" para finalmente, una vez que se hubo seleccionado una acción, esta tenia que ser ejecutada en el mundo real. Este enfoque llegó a ser conocido como la arquitectura sensar-planear-actuar (Murphy, 2000).

Una arquitectura GOFAI ilustrativa es "STRIPS" (por sus siglas en ingles *Stanford Research Institute Problem Solver*) (Fikes et al., 1971). STRIPS generaba planes para el robot Shakey, el cual se movía entre un conjunto de cuartos, empujando cajas y desempeñando un reducido número de acciones. Este sistema de planeación simbólico proporcionaba una estructura formal para la descripción de estados y un conjunto de de operadores o acciones aplicables. Para ello STRIPS usaba un análisis de medios-fines, una técnica de planeación de la GOFAI. Sin embargo, el desempeño de Shakey estaba restringido al bien definido entorno del laboratorio.

2.2. Limitaciones de la GOFAI

Entre los casos más reconocidos al seguir el paradigma cognitivista es la creación de jugadores artificiales computacionalmente programables capaces de ganar partidas contra campeones mundiales humanos en diversos juegos como el ajedrez o Jeopardy. Sin embargo, tal enfoque, basado en la representación abstracta del mundo externo al agente, no logró producir sistemas artificiales realmente autónomos e inteligentes, capaces de reaccionar y adaptarse a circunstancias inesperadas en el ambiente, los cuales puedan desempeñarse exitosamente en el mundo físico real (Pfeifer y Scheier, 2001).

Las "interfaces" con el mundo real, subestimadas y sin interes en la GOFAI, se convirtieron en la fuente de problemas practicos y fundamentales.

Hubo diversas razones para esto. Para empezar, los sistemas de procesamiento de símbolos no están bien preparados para lidiar con la naturaleza estocástica e impredecible de los entornos naturales. El procesamiento de símbolos requiere que la entrada sensorial del mundo sea reducida a un conjunto de estados bien definidos. El diseño de tal representación sensorial puede ser posible para un ambiente de laboratorio bien controlado, pero no es factible para los entornos típicos de los organismos biológicos. Entre otras razones, a causa de que la entrada sensorial es ruidosa, incompleta y con cierto grado de incertidumbre, puede contener objetos desconocidos y puede cambiar rápidamente de maneras inesperadas.

Incluso si se pudiera resolver el problema de crear una representación adecuada del mundo, las estrategias de planeación de los sistemas de procesamiento de símbolos serian proporcionalmente tan computacionalmente costosas como lo sea la complejidad del entorno (Dennett, 1984). Por tanto, el enfoque de procesamiento de símbolos no es adecuado para acciones de tiempo real (Pfeifer y Scheier, 2001).

Por otro lado el filosofo John Searle criticó fuertemente a la GOFAI con su experimento mental del "cuarto chino" (Searle, 1980), en el cual describe a las implementaciones computacionales de la GOFAI como procesadores de símbolos, incapaces de manejar semántica y por consiguiente incapaces de entender ni pensar.

El experimento del cuarto chino consiste en imaginar que hay una persona encerrada en una habitación en la que hay varios recipientes llenos de símbolos. Además hay una ranura por donde se pueden introducir y devolver símbolos. A la persona dentro de la habitación se le ha proporcionado un libro con reglas escritas, en un lenguaje que comprende. Dichas reglas le indican cómo combinar los signos de los distintos recipientes y cómo, dada una combinación de símbolos, organizar otra combinación. Ahora, por la ranura se introducen símbolos a la habitación, la persona usando el libro de reglas dentro del cuarto arma y devuelve los símbolos y combinaciones correspondientes. Fuera de la habitación hay un hablante nativo del chino y lo que introduce al cuarto son preguntas en chino, aunque la persona que esta dentro del cuarto no lo sabe, los símbolos devueltos son las respuestas a las preguntas. La idea central de este experimento es que la persona dentro del cuarto en realidad no comprende el idioma chino, aunque para el observador externo parece entenderlo.

El argumento de Searle es que a un sistema de procesamiento de símbolos le

ocurriría lo mismo que a la persona dentro del cuarto. Es decir, dicho sistema sólo cuenta con un programa para manipular símbolos (las reglas), pero no entiende la semántica de los símbolos.La semántica no se puede extraer de la sintaxis.

Posteriormente, Stevan Harnad describió el llamado "problema de cimentación de símbolos" (Harnad, 1990), el cual se refiere a cómo están vinculados los símbolos al mundo real y adquieren un significado intrínseco. En los sistemas de procesamiento de símbolos no hay un vinculo de los símbolos con el entorno (Ziemke, 1999). Esto implica que el diseñador del sistema de procesamiento de símbolos tenga en mente el significado de cada símbolo, no obstante que este significado es extrínseco al sistema mismo.

Adicionalmente Möller (1999) argumenta en contra del enfoque cognitivista en lo referente a la percepción. La construcción de la representación sensorial no debe ser creada por un proceso de diseño impuesto externamente pues se corre el riesgo de sobre-diseñar o sub-diseñar. El diseñador puede omitir características no evidentes en los datos sensoriales pero que sean importantes para el desempeño del agente. Además, el diseñador impone su visión del mundo al agente aunque la morfología y el equipamiento sensorial no son iguales. Más aún, esto último puede llevar al problema del homúnculo[1]. El diseñador del sistema se vuelve el homúnculo del agente.

Por otra parte, Möller (1999) enfatiza el proceso de auto-organización, el cual se supone toma lugar en las redes neuronales de los organismos biológicos. La auto-organización subyace de las interrelaciones y las regularidades estadísticas entre los diferentes flujos de datos modales, tanto sensoriales como motrices. El cognitivismo no toma en cuenta este proceso, impidiendo la captura y codificación de las interrelaciones entre las diferentes modalidades y mas aún la formación de la interrelación entre las acciones motrices y las consecuencias sensoriales de estas acciones.

2.3. Cognición corporizada

El paradigma del cerebro artificial que procesa símbolos no tuvo el éxito que se esperaba a largo plazo. Se ha encontrado evidencia en el campo de la robótica, donde esta propuesta difícilmente puede ser adoptada para imitar habilidades humanas tales como la percepción, la manipulación física y el habla

[1] El homúnculo se refiere a la creencia de la existencia en un agente de un observador interno e inmaterial que mira la representación sensorial e invoca el programa motriz apropiado

(Mingers, 2001).

El principal problema del enfoque cognitivista es el de subestimar la importancia del cuerpo del agente y su interacción en el entorno, y más aún de la separación del procesamiento sensorial y motriz (Wilson, 2002). Varios enfoques en la ciencias cognitivas abordan esas cuestiones, al mismo tiempo que rechazan la idea del procesamiento simbólico en el cerebro (Barsalou, 2008).

Primero, la corporización enfatiza la necesidad de un cuerpo de cierta morfología, con capacidades sensoriales y motrices específicas, que permita el desarrollo de la percepción y la cognición (Pezzulo et al., 2011; Wilson, 2002, 2008; Wilson et al., 2011). Este cuerpo es la base para la realización de cualquier acción motriz del agente, y define sus capacidades y sus limitaciones.

Segundo, estrechamente relacionado a la corporización, la "acción situada" enfatiza la relación mutua entre un agente y su entorno, ambos desde una perspectiva evolucionista e individual (Clark, 1998; Haugeland, 1998). La cognición esta cimentada en las relaciones sensorimotrices que el agente experimenta durante la interacción con su entorno. La noción de "estar situado" señala que el procesamiento cognitivo recae en el entorno del agente (Pfeifer y Scheier, 2001). Adicionalmente, la acción situada se enfoca en el estrecho acoplamiento de la percepción y la acción durante el logro de metas de un agente (Barsalou, 2008).

Tercero, Varela et al. (1991) introducen el concepto de "enacción" el cual se refiere a que las interacción entre el cuerpo de un agente, con su circuito sensorimotriz, y el entorno determina la manera en que es experimentado el mundo. Incluso señala que la percepción sin la acción no es del todo posible (Noë, 2004). Estos diferentes enfoques pueden ser interpretados como aspectos del mismo tema, a saber que la percepción y la cognición solo pueden emerger en agentes activos equipados con un cuerpo real en un ambiente especifico. Aunque cabe mencionar que la compatibilidad e interrelación de dichos enfoques es un tema de investigación abierto, este se encuentra fuera del alcance de esta tesis.

Además, un agente inteligente debe mostrar la capacidad de aprender. Este debe adaptar su comportamiento continuamente a un entorno cambiante e impredecible. La mayoría de las habilidades no están predefinidas, sino que son aprendidas durante la interacción del cuerpo del agente con lo que le rodea. En la base de este proceso de aprendizaje esta la adquisición de esquemas sensorimotrices.

En el enfoque corporizado, el "problema del marco de referencia" que alude a conservar consistente la representación interna del mundo con el mundo real exterior (Dennett, 1984), no es tan predominante como en el cognitivismo.

Esto se debe a que en el enfoque corporizado el modelamiento del mundo juega un papel menor, siguiendo la premisa de que el mejor modelo del mundo es el mundo mismo (Brooks, 1991). Un agente situado siempre puede "observar" el mundo para obtener los datos más recientes y precisos sobre él (Pfeifer y Scheier, 2001). Además, un agente situado solo requiere información muy específica sobre ciertos aspectos del mundo los cuales son relevantes para la tarea actual. No hay necesidad de un elaborado modelo del mundo.

En cuanto al problema de la cimentación de símbolos, que caracteriza a los sistemas cognitivistas, los investigadores están en la búsqueda de evidencia que demuestre la relación entre los procesos cognitivos de alto nivel y los procesos corporales y sensorimotrices de bajo nivel. Hasta ahora, lo más exitoso en la búsqueda de la cognición cimentada han sido las teorías de la simulación. Barsalou (2008) ha caracterizado la simulación como la reenacción de los estados perceptual, motriz e introspectivos adquiridos durante la experiencia con el mundo, cuerpo y la mente. Cada que vez que se experimenta algo el cerebro captura los estados a través de las diferentes modalidades y los integra en una representación multimodal almacenada en la memoria. Posteriormente, cuando se requiere del conocimiento para representar una categoría, se reactivan las representaciones multimodales capturadas durante la experiencia con los objetos. De esta manera, el cerebro realiza simulaciones para recrear la percepción, la acción y la introspección.

La simulación tiene la propiedad importante de que los patrones que el agente ha experimentado pueden ser recuperados y ejecutados fuera de linea (*off-line* [2]). De acuerdo a Barsalou (2008), los mecanismos de simulación están presentes a través de diversos procesos cognitivos, sugiriendo que la simulación provee una forma central de computo en el cerebro. Un ejemplo es la imagineria mental (Kosslyn, et al., 2006), la cual se puede definir como el proceso de recrear los estados perceptuales y motrices en la ausencia de estímulos exteriores (Thomas, 2014).

Por su parte Clark y Grush (1999) argumentan que el circuito simulador es una representación interna de estados extra-neuronales (por ejemplo los estados corporales). La ventaja es que el simulador puede ser instanciado a diferentes niveles de complejidad. La forma más simple es un modelo directo que provee la predicción de un estado sensorial futuro dado el estado actual y un comando motriz (para los detalles ver sección 2.4). De acuerdo a Clark y Grush (1999), esto sería una posible explicación del origen evolutivo del razonamien-

[2] El termino off-line se refiere a eventos distantes en tiempo o espacio

to *off-line*. Es decir, el agente emplea modelos primitivos antes o en lugar de operar directamente sobre el mundo.

Adicionalmente Hesslow (2002) hipotetizó que el sistema nervioso central podría ser capaz de generar largas cadenas de acciones simuladas y percepciones, de esta manera no sólo permite la planificación motriz, sino también tareas cognitivas como la resolución de problemas.

El mecanismo de simulación mejora la respuesta en tiempo-real del agente, ayuda a la planeación y apoya la imagineria mental entre otras capacidades. Este mecanismo es entrenado sobre la experiencia, es decir, cuando se ejecuta un comportamiento, se proveen las señales de entrenamiento. Posteriormente, puede ser usado para predecir los estados sensoriales futuros o recrear internamente todos los cursos de acción y sus consecuencias. La simulación es clave en las capacidades anticipatorias de un agente las cuales se cree juegan un rol crucial en todos los fenómenos cognitivos (Bar, 2007; Barsalou, 2003).

2.4. Modelos Internos

Las relaciones entre los comandos motrices y los estados sensoriales son determinadas por varios factores, entre ellos las propiedades del entorno y el cuerpo del agente. Existe evidencia de que el sistema nervioso central de los organismos biológicos construye estas relaciones internamente (Schaal et al., 2005; Shadmehr et al., 2005). Es por ello que estas construcciones son llamadas "modelos internos". Kawato menciona que los modelos internos son mecanismos neurales que pueden imitar las características de entrada/salida del aparato motriz (Kawato, 1999, pág 718). Además, los modelos internos son usados para describir el procesamiento e integración sensorimotriz. Estos fusionan de manera natural la información motriz y la sensorial y crean una representación multimodal (Wolpert y Kawato, 1998). Adicionalmente, estos modelos proveen a los agentes con las capacidades de anticipación, predicción y planeación mediante el uso de simulaciones internas (Schillaci et al., 2012b). El concepto de modelos internos tiene su origen en la teoría de control (Jordan y Rumelhart, 1992) y desempeña un papel importante en la investigación sobre control motriz.

Existen dos principales clases de modelos internos: los modelos inversos (MI), los cuales generan los comandos motrices para alcanzar un estado sensorial deseado partiendo del actual estado sensorial, y los modelos directos (MD), los cuales predicen las consecuencias sensoriales de las acciones del

agente. Mientras que los MI son principalmente requeridos para el control motriz, los MD sirven para múltiples propósitos. Consideraciones teóricas y hallazgos experimentales sugieren que los MD son utilizados en:

- La atenuación sensorial, la cual se refiere a como es que se bloquean los cambios en las sensaciones derivadas de los ego-movimientos (Blakemore, et al., 1999).
- La estimación del estado que resultaría de realizar una acción, aun cuando esta no se lleve a cabo (Grush, 2004; Wolpert et al., 1995).
- Identificación de acciones en el sistema de "neuronas espejo"[3] mediante la predicción de las intenciones de otro a través de la observación de sus movimientos.
- La imaginería mental, la cual se puede definir como la recreación de estados perceptuales y motrices, cuya función principal es la generación de predicciones sensori-motrices (Pearson, et al., 2015).

Incluso, cabe mencionar que, en años recientes ha emergido una perspectiva más elaborada de la predicción, de acuerdo a la cual, ésta representa el principio fundamental del funcionamiento cerebral, es decir, que se encuentra en el "centro de la cognición" (Pezzulo, et al., 2007).

Si los modelos internos son aceptados como bloques constructores del procesamiento e integración sensori-motriz, surge la pregunta: ¿Cómo son adquiridos estos modelos?. Para los organismos biológicos, los modelos internos representan ciertas capacidades de procesamiento de información del sistema nervioso central. Tales capacidades pueden ser aprendidas durante el transcurso de la vida del organismo. En robótica, el enfoque clásico de ingeniería intentaría describir la "planta" (que comprende el robot y su entorno) tan analíticamente precisa como sea necesario. Al conocer la planta se conoce el MD, por otra parte el MI puede ser diseñado utilizando las herramientas de la teoría de control. Pero este enfoque sólo es factible si la planta es completamente conocida analíticamente. Esto puede funcionar muy bien para ciertas aplicaciones industriales, pero no para los robots autónomos inmersos en entornos complejos. En donde puede cambiar tanto el "cuerpo" del agente, debido al uso y desgaste,

[3] Las neuronas espejo son un tipo específico de neuronas, encontradas en áreas pre-motoras de la corteza cerebral en la especie Macaco Rhesus, que disparan tanto en la realización de conductas motoras específicas como ante la observación de otros realizando las mismas conductas (Rizzolatti et al., 2006)

así como también el entorno. Entonces, al no conocer la planta de antemano, el robot tiene que adaptar sus modelos internos al entorno en el cual se esta moviendo y desempeñando, en otras palabras debe aprenderlos. En resumen, el aprendizaje de los modelos internos es una parte integral del procesamiento sensori-motriz, tanto para agentes biológicos como para agentes artificiales.

2.4.1. Descripción formal

Los modelos internos son mecanismos que están disponibles al agente y describen las relaciones entre las acciones y sus consecuencias. Como se ha establecido, básicamente hay dos clases de modelos internos: los modelos directos (MD) y los modelos inversos (MI).

El **modelo directo (MD)** o predictor recibe como entrada el estado sensorial del agente (S_t) y alguna acción del agente definida por un comando motriz M_t, ambos al tiempo (t). Como salida el MD produce el estado sensorial (S^*_{t+1}) para el siguiente tiempo ($t+1$). La representación esquemática del MD la podemos ver en la figura 2.1.

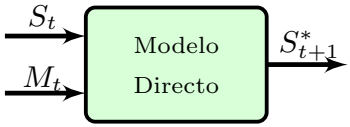

Figura 2.1: *Esquema del modelo directo.*

El MD también se puede describir como una función que produce el siguiente estado sensorial:

$$S^*_{t+1} = \mathrm{MD}(S_t, M_t) \tag{2.1}$$

El MD realiza predicciones de un solo paso, es decir, dado el estado actual t sólo predice el estado al instante siguiente $t+1$. Sin embargo, se puede realimentar el resultado de la predicción S^*_{t+1} como entrada sensorial junto con otro comando motriz M_{t+1} para obtener una segunda predicción (S^*_{t+2}). Repitiendo este proceso se consiguen predicciones de largo plazo (PLP) a un tiempo $t+n$, donde n representa la cantidad de veces que ha sido realimentada la predicción o el número de ciclos de predicción.

El MD se ha vuelto un concepto explicativo crucial en las investigaciones en control motriz. En este contexto las entradas son el estado sensorial actual y una copia del comando motriz ("copia eferente" la cual puede no llegar a ejecutarse en el entorno) y la salida es el estado sensorial ("descarga corolaria") predicho. Tal modelo es entrenado al ejecutar las acciones en el mundo real y usar la estimulación sensorial del mundo real para corregir el predictor. Este puede ser usado para (i) predecir el siguiente estado sensorial anticipadamente; (ii) distinguir la información sensorial auto-generada de la entrada sensorial generada por el entorno. El primer punto puede ser útil durante la ejecución de movimientos rápidos, tomando en cuenta que la retroalimentación propiocetiva requiere de cientos de milisegundos para transducirse y viajar desde los órganos sensoriales hasta el cerebro (Miall y Wolpert, 1996).

Cabe aclarar, que hay evidencia de la existencia del mecanismo predictivo en diferentes agentes biológicos (Crapse et al., 2008b). En el trabajo de Webb (2004) se plantea que organismos como los insectos utilizan copias eferentes para producir las descargas corolarias predictivas correspondientes, permitiendo así a los insectos producir respuestas reactivas rápidas, así como aprender a discriminar auto-estimulación de la estimulación ambiental. De igual manera en el trabajo de Crapse et al. (2008a) se menciona que el mecanismo predictivo en primates contribuye al desempeño sensori-motriz adecuado en su interacción con el mundo. En los trabajos de Wolpert et al. (1998), Ramnani (2006) y Franklin et al. (2011) se muestra evidencia del aparato predictivo en el cerebelo y su influencia en el comportamiento de los organismos biológicos.

El **modelo inverso (MI)** o controlador genera el comando motriz (M_t) al tiempo (t) necesario para alcanzar un estado sensorial deseado (S_{t+1}) para el tiempo ($t+1$) partiendo del estado sensorial (S_t) al tiempo (t). El diagrama esquemático lo podemos ver en la figura 2.2.

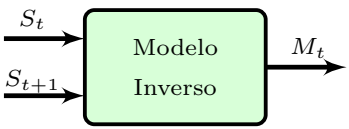

Figura 2.2: *Esquema del modelo inverso.*

El MI se puede entender como una función que provee el comando motriz para alcanzar el estado sensorial deseado (S_{t+1}):

$$M_t = \mathrm{MI}(S_t, S_{t+1}) \tag{2.2}$$

Donde M_t es una estimación del comando motriz necesario para producir S_{t+1} al tiempo siguiente.

Es pertinente señalar que los modelos inversos son generalmente mas difíciles de aprender. Esto tiene que ver, entre otras cosas, a que la señal de error usada para entrenar dichos modelos tiene que ser transformada del ámbito sensorial al ámbito motriz. Por ejemplo, cuando lanzamos un dardo, el error recibido está en coordenadas visuales. Este error debe ser convertido en un error del comando motriz para que sea apropiado para actualizar el modelo inverso.

Adicionalmente, nos encontramos, también, con el problema de la redundancia. El cual se refiere a que, la multiplicidad de grados de libertad en un sistema conlleva a que haya múltiples maneras en que pueda ser realizada la misma tarea, llevando a una abundancia de soluciones posibles (Franklin y Wolpert, 2011).

Por dichas razones es que es importante elaborar un mecanismo que posibilite la adquisición de un esquema sensorimotriz y a su vez permita su adecuada explotación como modelo inverso.

Los modelos directos pueden ser usados para facultar a un agente a diferenciar los efectos sensoriales que son consecuencia de las propias acciones, de los efectos sensoriales provocados por causas externas. La diferencia entre el estado sensorial predicho por el MD y el estado sensorial real después de la ejecución de un comando motriz, es una señal que puede ser usada para determinar la fuente de los cambios sensoriales.

Adicionalmente, la predicción producida por el MD puede ser usada para cancelar los efectos sensoriales auto-producidos. Un ejemplo clásico de este tipo de razonamiento es el principio de reaferencia sugerido por Holst et al. (1950). Ellos describieron para varios sistemas neuromusculares, entre ellos los movimientos y acomodación oculares, como es que la copia eferente anula la "reaferencia", es decir la señal transmitida por los receptores sensoriales en respuesta al comando motriz eferente. Por ejemplo, cuando sujetos con los músculos oculares temporalmente paralizados intentan realizar movimientos oculares, experimentan una variación del entorno visual en la dirección del movimiento aunque este no se lleva a cabo.

Se ha presentado evidencia más reciente de la atenuación sensorial de los cambios sensoriales auto-producidos en el estudio de Blakemore et al. (1999). En estos experimentos, se le pedía a sujetos que se hicieran cosquillas a través

de una interfaz robótica. Los experimentadores controlaron el retraso entre la producción del estímulo de parte de los sujetos y la ejecución por parte de la interfaz robótica. En este experimento se reportó que el incremento en el retraso produce mayor sensibilidad al cosquilleo. Este efecto es adjudicado al MD cuya predicción atenúa el efecto sensorial de hacerse cosquillas entre más cercana es la predicción a la sensación experimentada. Vale la pena señalar que, la cancelación sensorial predictiva ha sido observada también en otros agentes biológicos, como por ejemplo en el sistema electrosensorial de los peces eléctricos (Bell, 2001). Mediante este sistema dichos peces pueden detectar organismos cercanos al discriminar los campos eléctricos auto-generados de aquellos generados por otros peces.

En un estudio posterior Blakemore, et al. (2000) empleo una version simplificada de su experimento para explorar las regiones cerebrales dedicadas a la predicción de las consecuencias sensoriales. Basados en datos de fMRI, los autores concluyeron que el cerebelo esta involucrado en la predicción de consecuencias sensoriales especificas de los movimientos y en proveer la señal que es usada para atenuar la respuesta somatosensorial a la estimulación táctil autoproducida. Cabe mencionar la investigación llevada a cabo por Frith, et al. (2000), la cual sugiere que la falla en la capacidad para detectar las acciones auto-producidas podría ser la causa de la esquizofrenia, produciendo una percepción alterada del mundo.

Por otro lado, en el control motriz, las señales eléctricas propioceptivas del sistema nervioso requieren de cientos de milisegundos para la adecuada transducción y transporte, desde los órganos sensoriales hasta el cerebro (Wolpert, et al., 2003). La latencia de dichas señales propioceptivas generaría trayectorias difíciles de controlar. La predicción llevada a cabo por el MD podría sustituir la información propioceptiva y de este modo afinar las respuestas motrices (Miall, et al., 1993).

Por último, los MD pueden ser el mecanismo básico constructor del proceso de simulación interna en su forma más simple (Grush, 2004; Jeannerod, 2001). Esto a su vez conlleva a que puedan ser considerados como un modelo computacional de imaginería mental (Moulton et al., 2009).

2.4.2. Modelos internos en la robótica

En diversas investigaciones sobre robótica cognitiva se han utilizado modelos internos, estos permiten modelar comportamientos sencillos y básicos de agentes naturales.

Integración multimodal

Una de las investigaciones en las que se hace uso de modelos internos es el trabajo de Hoffmann et al. (2004) en el que se utilizó un modelo directo para realizar predicciones visuales en un agente artificial. En este trabajo se utilizaron PLP para que el agente fuera capaz de determinar su posición respecto al centro de un circulo de obstáculos, los cuales formaban el entorno experimental. En un trabajo posterior, Hoffmann (2007) utilizó un esquema muy similar que usaba un modelo directo, pero prediciendo imágenes en lugar de distancias. Este esquema le permitió a un agente determinar la salida de un laberinto de obstáculos.

Cabe mencionar el trabajo de Lara et al. (2006) que utiliza un MD en un robot móvil para la predicción de situaciones no deseadas en la tarea de trasladarse de un punto a otro evadiendo obstáculos. Así mismo, se reconocen los cambios en el entorno provocados por factores externos al agente, esto se logra al comparar la predicción del MD con el estado sensorial real después de ejecutar alguna acción.

En el trabajo de Dearden et al. (2005), un agente artificial realiza movimientos aleatorios en su pinza mientras visualmente observa y aprende las consecuencias visuales de estas acciones, codificando un MD. El MD fue construido con una red Bayesiana, cuya estructura y parámetros fueron aprendidos usando los datos sensorimotrices reunidos durante un comportamiento explorativo en el espacio motriz. La estrategia de exploración aleatoria, o balbuceo motriz, elige comandos motrices de manera aleatoria del espacio de posibles movimientos. El MD aprendido es usado, posteriormente, para permitir al agente la imitación de un simple gesto de saludo de un humano.

Vale la pena señalar que las estrategias de exploración aleatorias, tales como el balbuceo motriz aleatorio, a pesar de su utilidad para la exploración, han mostrado no ser optimas. Esto se cumple especialmente, cuando son aplicados a sistemas robóticos caracterizados por un alto número de grados de libertad. Es por ello que se han propuesto comportamientos de exploración más eficientes. En los trabajos de Baranes et al. (2013) y Rolf et al. (2014) se presenta un mecanismo de exploración por objetivo (balbuceo por objetivo), el cual permite el aprendizaje activo de los modelos inversos. En esta metodología propuesta, la exploración se realiza en el espacio de la tarea, eficientando la exploración.

Esquema Corporal

Por otra parte, el trabajo de Hoffmann, et al. (2010) propone que el cerebro integra la información, presente en las corrientes modales, acerca del cuerpo de un individuo en un *esquema corporal*. En dicho esquema se conserva una representación actualizada de las posiciones de las diferentes partes de nuestro cuerpo en el espacio y en el espacio de la modalidad sensorial individual, así como de su combinación. En los trabajos de Schillaci, et al. (2012a) y Hoffmann (2014) se propone que la integración de un esquema corporal se puede realizar mediante la asociación de las acciones propias con sus respectivas consecuencias sensoriales. Es utilizando esta asociación que el agente puede conocer sus propias capacidades motrices.

Otro trabajo relacionado es el de Escobar, et al. (2012), en el que un robot móvil forma asociaciones multimodales, integrando las modalidades visual, táctil y motriz. Dicha asociación se logra mediante un modelo directo, el cual fue entrenado con información proveniente de la ejecución de trayectorias aleatorias en una arena con obstáculos. El modelo directo resultante permite al robot navegar evitando situaciones no deseadas al realizar predicciones de largo plazo de las consecuencias sensoriales de sus acciones. Además, este sistema codificó un mapeo corporal, pues proveyó de un mecanismo para determinar si es que el robot, al moverse hacia adelante, colisionará con los objetos frente a él. Tal mapeo corporal le permitió al agente realizar la tarea de determinar, entre un conjunto de obstáculos dispuestos en forma circular alrededor del agente, por donde podía pasar sin colisionar.

Coordinación visuo-motriz

En cuanto al papel que los modelos internos desempeñan en la coordinación visuo-motriz podemos referir la investigación de Saegusa, et al. (2009), en la que se estudió la adquisición de las habilidades de coordinación visuo-motriz en un robot humanoide. Aquí se usó un comportamiento de exploración inteligente basado en una función de confianza dependiente del error de predicción[4]. Adicionalmente encontramos el trabajo de Brandao, et al. (2013), en el cual se presenta un sistema para la integración de locomoción y movimientos del cuerpo de un robot humanoide para incrementar el espacio de alcance. Dicho sistema es adquirido a través de un mecanismo de aprendizaje de la coordinación visuo-motriz. En este trabajo se utilizó la exploración dirigida por

[4] El error de predicción es el error producto de la comparación entre el estado modal predicho y el deseado

objetivos. También en el contexto de coordinación visuo-motriz se encuentra el trabajo propuesto por Schenck, et al. (2011) en el que se utiliza un brazo robótico y un par de cámaras para efectuar la tarea visualmente guiada de tomar objetos. En este trabajo se codificaron controladores independientes para las cámaras y el brazo, y un predictor o MD de la entrada visual. Mientras los controladores producían los comandos motrices necesarios para localizar el objeto de interés y tomarlo, el MD actuó como verificador de la posición deseada en el proceso de fijación del campo visual de las cámaras sobre el objeto de interés.

En la investigación llevada a cabo por Yamashita et al. (2012), se presenta un sistema de redes neuronales recurrentes con sesgo paramétrico aplicada en un agente robótico humanoide. Esta red produce una predicción sensorial y propioceptiva, mediante la cual se calcula el error de predicción, que a su vez es usado para la distinción y selección de tareas. En este trabajo se modelan daños en las conexiones entre las capas neuronales provocando una deficiente propagación del error y generando con ello comportamientos erráticos, los cuales son similares a los presentados en el padecimiento de esquizofrenia.

Acople MD-MI

Por otro lado en diversos trabajos se ha propuesto el acoplamiento del MI y del MD para realizar diferentes tareas. La idea general del acoplamiento entre el MI y el MD es generar un comportamiento que se beneficie de ambas funcionalidades individuales.

La idea del acoplamiento fue utilizada en la arquitectura MOSAIC (*Modular Selection and Identification for Control*) (Haruno, et al., 2001; Wolpert y Kawato, 1998). En esta arquitectura se crean multiples pares acoplados de MI-MD. La arquitectura propone la selección del par MI-MD que proporcione los comandos motrices más apropiados para un entorno dado, esto se realiza asignando un valor de responsabilidad a cada par de acuerdo a la evaluación del error de la predicción de su MD asociado. El valor de responsabilidad cuantifica la contribución de cada MI al comando motriz de salida de la arquitectura. Este procedimiento ocasiona que el comando final esté altamente determinado por el par mas apto para la tarea y ambiente dados.

En la investigación de Möller et al. (2008) se utiliza un acople MI-MD para la planeación de estrategias de navegación mediante simulaciones internas, donde un robot móvil simulado aprende a distinguir entre caminos cerrados y corredores, anclando estos conceptos en el espacio sensorial y motriz. A

través de la interacción con el entorno, el agente adquiere un modelo directo visuo-táctil que le permite predecir como esta cambiando la entrada visual bajo sus movimientos y que movimientos conducen a una colisión. Adicionalmente, el agente aprende un modelo inverso para sugerir que acciones deben ser simuladas en la predicciones de largo plazo.

Esquemas de acoplamiento similares han sido utilizados en otras tareas, por ejemplo en el trabajo de Schillaci et al. (2012b) se utilizó un robot humanoide sobre el que se codificaron varios pares MI-MD con el fin de reconocer acciones llevadas a cabo por un agente externo. Donde cada par acoplado de modelos internos correspondía a un comportamiento aprendido por auto-exploración del agente. El reconocimiento de acciones se realizó comparando la salida de cada par de modelos internos con la situación real y seleccionando aquel par que presentaba menor error.

Neuronas espejo

En el artículo de Oztop, et al. (2006) se presentan una revisión de varios modelos computacionales para la implementación de neuronas espejo, en los cuales se enfatiza el uso de acoplamientos MI-MD para el reconocimiento de acciones. Un trabajo desarrollado en este contexto es el de Demiris et al. (2006) en donde se propone el sistema "HAMMER" (por sus siglas en ingles *Hierarchical Attentive Multiple Models for Execution and Recognition*), una implementación computacional para el reconocimiento de acciones en un agente robótico. Dicho sistema utiliza acoples de modelos internos y atención visual. El sistema desarrollado provee la capacidad de reconocer un repertorio de acciones básicas.

También, para el reconocimiento de acciones encontramos el trabajo desarrollado por Arceo, et al. (2013), donde se utiliza un acoplamiento de MI-MD para el aprendizaje, reconocimiento y recreación de acciones. En este trabajo se utilizó un par de agentes robóticos móviles, uno de los cuales fue el agente dotado del sistema de reconocimiento de acciones y el otro tomó el papel de agente demostrador. Cabe destacar que el aprendizaje de las acciones se realizó con el agente que posteriormente sería el que realizaría el reconocimiento. Esto implicó, que se apostó por que el sistema mismo fuera el que hiciera el emparejamiento de las ego acciones con las de un agente externo. Como conclusión se menciona que si las Neuronas Espejo en zonas premotoras funcionan como predictores de las conductas observadas o a realizarse, a partir de un aprendizaje asociativo de experiencias sensorimotrices, es posible entonces que dicho sis-

tema pueda ser diseñado para su simulación en agentes autónomos artificiales a partir de Modelos Directos e Inversos.

Finalmente, es pertinente referir el estudio llevado a cabo por Schillaci, et al. (2013) para la distinción del cuerpo propio, en el que se implementó un mecanismo de aprendizaje de modelos internos a través de la auto-exploración en un robot humanoide. Dichos modelos internos fueron consecuentemente usados para predecir trayectorias simples del brazo del agente robótico, y también, para distinguir entre los movimientos auto-generados y movimientos del brazo ejecutados por un robot diferente.

Capítulo 3

Herramientas computacionales

En este trabajo de tesis, se propone una nueva arquitectura computacional para la codificación de esquemas sensorimotrices de bajo nivel dentro del paradigma de la Cognición Cimentada: "Arquitectura de modelos internos auto-organizados" (SOIMA por sus siglas en ingles Self-Organizing Internal Models Architecture).

SOIMA se basa en dos principales mecanismos de aprendizaje:

- El primero consiste de *Mapas Auto-Organizados* (SOMs) (Kohonen, 1990) que capturan las regularidades y crean grupos (*clusters*) de la información modal proveniente del entorno o de otros SOMs.
- El segundo codifica los modelos internos por medio de conexiones entre los mapas SOMs, las cuales son moduladas utilizando aprendizaje Hebbiano. Este proceso de asociación hebbiana genera patrones que representan los esquemas sensori-motrices.

Esta propuesta de codificación de modelos internos usando SOMs y aprendizaje hebbiano forman la base y el modulo atómico para la construcción de esquemas sensorimotrices complejos, y constituye la principal contribución de este trabajo. La arquitectura permite una estrategia de aprendizaje integrada y provee medios para la construcción de esquemas sensori-motrices acoplados de forma flexible.

La mayoría de los enfoques previos de implementación de modelos internos, como se ha reportado en el capítulo anterior, sección 2.4, se construyen utilizando diferentes sustratos computacionales que se conectan unos con otros para sintetizar el modelo acoplado MI-MD. Los sustratos pueden incluso ser de diferente naturaleza (por ejemplo diferentes tipos de redes neuronales), lo cual obliga a usar distintas estrategias de aprendizaje para cada modelo. En varios casos, incluso, los modelos resultantes se adecúan para resolver una tarea específica.

Nuestro enfoque codifica el acoplamiento de los modelos en el mismo sustrato, lo cual, permite la implementación de modelos internos y esquemas sensori-

motrices modulares y flexibles. Estas capacidades pueden ser explotadas de maneras interesantes como se discutirá mas adelante. Por el momento, es conveniente mencionar la inspiración biológica sobre la que se basa la SOIMA.

3.1. Inspiración Biológica

La plasticidad cerebral regula nuestra capacidad para aprender y para modificar nuestro comportamiento. Dicha plasticidad es inducida en la vías neurales y las sinapsis por la experiencia corporal con el ambiente externo. En la literatura de neurociencias, ha sido propuesto que el vasto flujo de información multimodal a través de la corriente sensorial y motriz esta integrado en una especie de esquema corporal, o representación corporal. Tal representación corporal, fundamental para la planeación de acciones y para la interacción eficiente con el entorno (Hoffmann et al., 2010), puede ser adquirida y refinada sobre el tiempo, principalmente durante las etapas de desarrollo pre-natal.

Por ejemplo, Rochat (1998) mostró que los infantes exhibían, a la edad de 3 meses, auto-exploración visual y propioceptiva sistemática y se volvían sensitivos a las características especificas e invariantes de ellos mismos. Los autores incluso reportaron que los infantes, a la edad de 12 meses, poseen el sentido de un espacio calibrado de su cuerpo como una entidad organizada perceptualmente la cual pueden monitorear y controlar, es decir la noción de un esquema corporal (Rochat et al., 1998). Como discutieron Maravita et al. (2003) y Maravita et al. (2004), evidencias convergentes de diferentes estudios sugieren que el cerebro de los primates construye diversas representaciones del espacio centradas en partes del cuerpo, basado en la integración de diferentes señales motoras y sensoriales, tal como la información visual, táctil y propioceptiva.

Los receptores sensoriales y los sistemas efectores parecen estar organizados en mapas topográficos que están alineados con precisión a través de las modalidades (Cang et al., 2013; Udin et al., 1988). Tales mapas topográficos se auto-organizan a través del desarrollo del cerebro de tal manera que las regiones adyacentes procesan partes sensoriales espacialmente cercanas en el cuerpo. Kaas (1997) reporta un número de estudios mostrando la existencia de tales mapas en los sistemas visual, auditivo, olfatorio y somatosensorial, así como en partes de las áreas motrices del cerebro.

Toda esta evidencia sugiere que la cognición se basa sobre estructuras de mapeo corporal auto-organizadas que integran información sensorimotriz. Pero

¿Cómo es que se realiza esta integración? El trabajo de Damasio (1989) y Meyer et al. (2009) proponen un marco funcional de integración multimodal apoyado por la teoría de las zonas de convergencia-divergencia (CDZ) de la corteza cerebral. Esta teoría sostiene que áreas corticales particulares pueden actuar como conjuntos de apuntadores a otras áreas y, por lo tanto, relacionan diversas redes corticales entre si.

Estas zonas serian las responsables de vincular entre si la información de varias modalidades sensoriales que pertenecen a un mismo concepto. Por ejemplo, la integración de la información visual al observar un plato de comida y su información olfativa particular. De acuerdo a Damasio et al. (1994) de esta integración se deriva la capacidad de la memoria de recrear la información multimodal usando pistas modales parciales, por ejemplo la estimulación unimodal visual puede recrear la sensación multimodal permitiendo la recreación olfativa del estímulo.

Las CDZ integran redes de las áreas corticales de bajo nivel (cercanas a las modalidades sensoriales o motrices) con los constructos amodales de alto nivel, lo cual permite la integración multimodal y la extracción de regularidades desde la información sensorial pura, compleja y sin segmentar.

En el proceso de convergencia del CDZ, la información modal se propaga hacia las zonas de integración multimodal; mientras que en el proceso de divergencia, la información multimodal se propaga hacia las redes modales generando la recreación de estados sensoriales o motrices. En este sentido es que la bidireccionalidad de la propagación, provee el mecanismo de la imagineria mental y la recreación de estados sensori-motrices.

Esta capacidad bidireccional es, entonces, fundamental para la integración multimodal. La falta de esta propiedad es precisamente una de las principales limitaciones de las arquitecturas cognitivas actuales y que nuestro modelo aborda.

La arquitectura propuesta preserva las ideas estructurales, presentadas por Damasio, sobre las propiedades del cerebro de auto-organización e integración multimodal, todo esto en el contexto de los modelos internos. Esto permite la construcción de un mecanismo para la integración y generación de esquemas sensorimotrices multimodales en el contexto de la cognición corporizada.

Los detalles de la implementación de los mecanismos de aprendizaje en SOIMA se describen en la siguiente sección.

3.2. Mapas auto-organizados

Los mapas auto-organizados (SOM por sus siglas en ingles "Self-Organizing Map") fueron desarrollados por Teuvo Kohonen a principios de los 80's (Kohonen, 1982a,b, 1990). El SOM básico puede ser visualizado como un arreglo de neuronas, las cuales se sintonizan a varios patrones o clases de patrones que se presentan como entrada. El proceso de aprendizaje es por competencia y no supervisado, lo cual significa que no hay un conocimiento *a priori* que defina la salida correcta para una entrada dada.

En la versión básica, correspondiente a cada entrada sólo se activa una unidad en el mapa (unidad ganadora) en un tiempo determinado. Las unidades en el arreglo tienden a ordenarse topológicamente durante el proceso de aprendizaje de acuerdo a algún sistema coordenado no lineal relacionado a las características de las entradas. (Kohonen, 1995). Al entrenar los SOMs se genera una organización topológica en un espacio de menor dimensión (2D, 3D, etc.) que la del espacio de los datos de entrada.

Los SOM son un tipo de red neuronal artificial que realiza una *cuantización vectorial*. La cuantización vectorial se refiere al ajuste de una función de densidad de probabilidad a un conjunto discreto de vectores prototipo, tal que cualquier punto extraído de la distribución puede ser asociado a un vector prototipo.

El principal uso de la cuantización vectorial es particionar el espacio vectorial de entrada en sectores, cada uno de los cuales es representado por un solo vector prototipo. El conjunto de vectores prototipo forman lo que se conoce como diccionario (*codebook*) y conforman los niveles de cuantización. Cada vector en el diccionario tiene asignada una dirección o etiqueta. La cuantización de un vector de entrada se realiza mediante la asignación de la dirección del vector "más cercano" en el diccionario.

La definición matemática de la cuantización vectorial es la siguiente:

Consideremos una función de densidad de probabilidad $f(x)$ sobre una variedad compacta $\Omega \in \mathbb{R}^K$ con elementos $\vec{x} = [x_1 \dots x_K]$. Un cuantizador vectorial es una función Φ que mapea Ω a un conjunto de n vectores prototipo (*code words*) $D = \{\vec{\mathrm{w}}_i \in \mathbb{R}^K\}_{1 \leq i \leq n}$ que forman un diccionario (*codebook*). Un grupo (*cluster*), el cual forma una partición de Ω, está definido como

$$C_i \stackrel{\text{def}}{=} \{x \in \Omega | \Phi(x) = \mathrm{w}_i\} \tag{3.1}$$

Los grupos cumplen las siguientes condiciones:

1. $C_i \cap C_j = \emptyset, \quad i \neq j, \quad i, j = 1, \ldots, n$
2. $\bigcup_{i=1}^{n} C_i = C^K$

Los SOM toman estos conceptos como base para el desarrollo de su mecanismo de aprendizaje, el cual, es descrito en la siguiente subsección.

3.2.1. Aprendizaje SOM

Supongamos algún conjunto de datos que tienen que ser mapeados a un arreglo SOM de neuronas como el mostrado en la Figura 3.1; el conjunto de datos de entrada esta descrito por un conjunto de vectores $\mathrm{x} \in R^n$. Cada neurona j en el mapa contiene un vector prototipo de pesos $\mathrm{w}_j \in \mathbb{R}^n$, el cual tiene el mismo número de elementos que los vectores de entrada.

En la Figura 3.1 se puede observar la estructura básica de una mapa autoorganizado en el que los datos de entrada son colores en el modelo RGB. Cada neurona del mapa está representada por un circulo en el arreglo. El vector prototipo correspondiente a cada neurona ha sido representado por un diagrama de lineas que, en este SOM particular, consta de 3 valores correspondientes a un color en RGB. En el tiempo actual t, el vector x_t es aquel que se encuentra en la entrada de la red, dicho vector se presenta a todos las neuronas del mapa. La neurona resaltada u_t es la neurona ganadora correspondiente al vector x_t. La zona dentro del circulo alrededor de u_t muestra las neuronas vecinas que serán afectadas durante el aprendizaje SOM.

El algoritmo SOM realiza un proceso de regresión. Por lo tanto, los valores iniciales de los vectores prototipo, w_j, pueden ser seleccionados aleatoriamente. En aplicaciones practicas, sin embargo, se obtienen mejores resultados si los vectores prototipo son inicializados de acuerdo a algún criterio relativo a los datos de entrenamiento (Kohonen, 1995). Entre los métodos de inicialización de los vectores se encuentran:

- Poda: Es un procedimiento que se adecua a la estadística de los vectores de entrenamiento, en donde los vectores prototipo iniciales pertenecen a los vectores de entrenamiento. Con la restricción de que, la distancia entre cualquier vector de entrenamiento y al menos uno de los vectores prototipo, tiene que ser menor que un cierto umbral.
- Agrupación: Este proceso se inicia con todos los vectores de entrenamiento como vectores prototipo, se forman grupos de dos elementos y estos

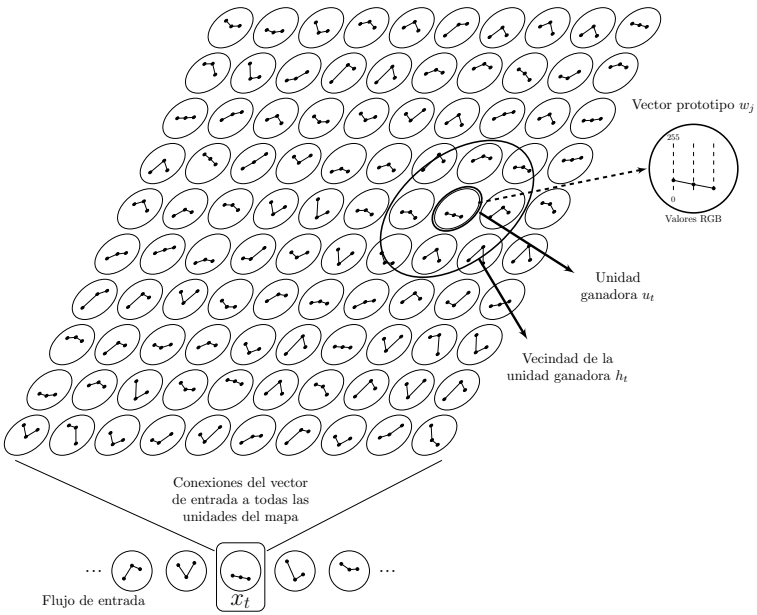

Figura 3.1: *Estructura básica de un mapa auto-organizado (SOM) para una clasificación de colores RGB.*

son sustituidos por su centroide. Este proceso de repite hasta que se tiene el número de vectores prototipo correspondiente al tamaño del SOM.

- Separación: Se comienza con el centroide de los vectores de entrenamiento como único vector prototipo. Luego, éste se divide en dos vectores haciendo pequeñas perturbaciones sobre sus elementos. Se repite este procedimiento hasta obtener el número de vectores prototipo correspondiente al tamaño del mapa.
- Vectores propios: Los vectores prototipo son tomados del subespacio dosdimensional generado por los dos vectores propios principales de los vectores de entrenamiento.

El algoritmo de auto-organización crea un mapeo ordenado en base a la iteración sobre las siguientes tareas básicas:

1. Se toma un vector de entrenamiento x_t y se calcula la activación de cada neurona en el mapa. Se identifica cual es la neurona de mayor activación y se declara como *neurona ganadora*.
2. Se ajustan hacia el vector de entrada los vectores prototipo tanto de la neurona ganadora como de sus neuronas vecinas en el mapa de acuerdo al principio de aprendizaje.

Respecto a la primer tarea, la activación A_j de la neurona j en el SOM está relacionada con la distancia de esa neurona al vector de entrada x_t, es decir, con una medida que evalúe la similitud entre los vectores w_j y x_t. Dicha medida es, normalmente, la distancia euclidiana. Sin embargo, en nuestro caso, estábamos interesados en evaluar la diferencia entre los vectores no sólo en términos de su distancia relativa sino también en términos de su orientación. La similitud coseno proporciona la diferencia en orientación entre un par de vectores, por tanto, usamos ambas medidas para el calculo de la activación:

$$A_j = \frac{1}{2}\left(\|\mathrm{x}_t - \mathrm{w}_j\| + 1 - \frac{\mathrm{x}_t \cdot \mathrm{w}_j}{\|\mathrm{x}_t\|\|\mathrm{w}_j\|}\right) \tag{3.2}$$

donde el primer término es la distancia euclidiana entre x_t y w_j y el segundo término es la similaridad coseno. El nodo ganador es aquel con la menor activación.

Para la segunda tarea, una vez que se tiene el nodo ganador, se ajustan de los vectores prototipo de acuerdo al $\Delta\mathrm{w}_j$ calculado en la siguiente ecuación

$$\Delta \mathrm{w}_j = \alpha(t) h_j (\mathrm{x}_t - \mathrm{w}_j) \tag{3.3}$$

donde α es la tasa de aprendizaje como función del tiempo y h_j es la función de vecindad de la neurona j definida como

$$h_j = e^{(-\beta_j / 2\sqrt{n})} \tag{3.4}$$

donde β_j es la distancia entre la neurona j y la neurona ganadora, y n es el número total de nodos en el mapa. Si β_j es mayor que el tamaño de la vecindad v entonces $h_j = 0$. La v es monotónicamente decreciente desde v_i a $v_f = 1$, donde v_i y v_f son el tamaño de vecindad inicial [1] y final respectivamente. El mapa se considera estable cuando $v = v_f$.

Finalmente $\alpha(t)$ es la tasa de aprendizaje, la cual crece en función del tiempo, y esta definida por:

$$\alpha(t) = \alpha^i \left(\frac{t(\alpha^f - \alpha^i)}{v_i - v_f} \right) \tag{3.5}$$

donde α^i y α^f son las tasas de aprendizaje inicial y final respectivamente, dadas como parámetros del sistema al comienzo del entrenamiento, y t es la época de aprendizaje actual.

Al comienzo del proceso de aprendizaje el radio de la vecindad es grande, pero conforme se va desarrollando el aprendizaje este radio se va estrechando. Esto asegura la obtención de un ordenamiento global al inicio del aprendizaje, mientras que hacia el final, cuando el radio es pequeño, las correcciones locales de los vectores prototipo en el mapa son más específicas.

La idea básica en el proceso de aprendizaje SOM es que, para cada vector de entrada x, la neurona ganadora y las de su vecindad cambien para acercarse a x en el espacio de los datos de entrada. Durante el proceso de aprendizaje los cambios individuales pueden ser contradictorios, pero el resultado final del proceso es un ordenamiento sobre el mapa en los vectores prototipo. Si el número de ejemplos de entrada disponibles es pequeño, los ejemplos deben ser presentados varias veces al algoritmo SOM. En la Figura 3.2 se muestran el estado inicial aleatorio, el estado intermedio y el mapa final para el SOM (Fig. 3.1) que recibe como entrada ejemplos de colores RGB.

[1] Este valor inicial regularmente es tomado como el 15 % del tamaño del mapa

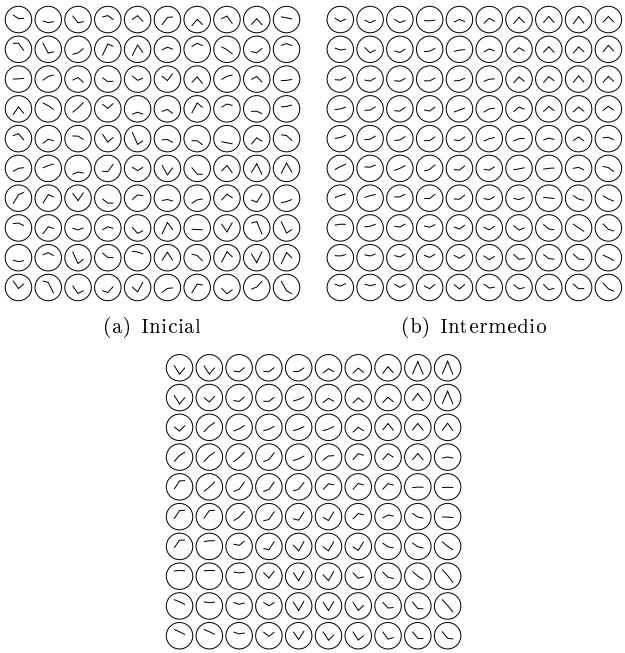

(a) Inicial (b) Intermedio

(c) Final

Figura 3.2: *Diferentes estados del SOM durante el entrenamiento, cada circulo representa la información de cada neurona en el mapa; se puede observar que al inicio del entrenamiento (a) las neuronas que tienen cercanía topológica no presentan similitudes de ningún tipo, conforme avanza el entrenamiento a fases intermedias (b) comienza a surgir un ordenamiento general del mapa, sin embargo hacia el final (c) se apreciar el ordenamiento de los vectores prototipo al tiempo que se ha alcanzado una especificidad de las regiones*

3.2.2. Calidad del SOM

Una métrica comúnmente utilizada para verificar el correcto entrenamiento de los SOM corresponde a la *distorsión de la cuantización vectorial* (Rynkiewicz, 2006). En términos generales, esta medida indica que tan bien representado esta el espacio de entrada por las unidades del mapa SOM. La distorsión de la cuantización vectorial esta definida como el error cuadrático

medio. Dado el conjunto finito $\{\mathrm{x}_i\}$ de p observaciones no sesgadas, la distorsión puede ser estimada por

$$\xi \stackrel{\text{def}}{=} \frac{1}{p} \sum_{i=1}^{n} \sum_{\mathrm{x}_j \in C_i} \|\mathrm{x}_j - \mathrm{w}_i\|^2 \tag{3.6}$$

donde $\{\mathrm{w}_i\}$ es el conjunto vectores prototipo para las n neuronas de un SOM, y C_i es el *campo receptivo* de la unidad i descrito como un grupo por la ecuación 3.1.

En nuestro sistema, adicionalmente a la distorsión, hemos utilizado la *distancia entre neuronas adyacentes*. Esta medida nos proporciona una noción sobre el numero adecuado de neuronas en el SOM para representar el espacio de entrada. Esto se deriva de que en un SOM de tamaño adecuado la diferencia entre neuronas adyacentes es pequeña, los cambios abruptos entre neuronas adyacentes indican que los campos receptivos del SOM son muy grandes y por tanto hay una representación pobre del espacio de entrada.

La distancia entre neuronas adyacentes se calcula como el promedio de la distancia euclidiana de cada neurona a sus vecinas adyacentes. Considerando como vecinas sólo a cada par de neuronas directamente adyacentes en cada dimension del mapa, es decir, en un mapa 2-dimensional se considera una 4-vecindad y en un mapa 3-dimensional se considera una 6-vecindad para el calculo.

Cabe mencionar que el análisis matemático del algoritmo SOM ha sido abordado en diversos trabajos. La prueba de la convergencia del proceso de aprendizaje SOM en el caso uni-dimensional fue dada por Cottrell, et al. (1998). Las propiedades de la convergencia son estudiadas más generalmente en Flanagan (2001); Horowitz et al. (1996) y Fort (2006). Varios detalles acerca de la selección de parámetros, variantes del mapa y varios otros aspectos han sido cubiertos en la monografía de Kohonen (1995). Sin embargo el punto central de la presente investigación es utilizar al SOM como herramienta para capturar las regularidades de un flujo de información y crear las relaciones multimodales sobre estas regularidades en el ordenamiento topológico de la red.

3.2.3. Características de los SOM

Es pertinente mencionar algunos aspectos de las redes SOM que hacen deseable su uso en este trabajo.

1. La noción más típica de los SOM es considerarlo con un modelo de red neuronal artificial del cerebro, especialmente, de los mapas ordenados encontrados experimentalmente en la corteza cerebral (Cang y Feldheim, 2013; Kaas, 1997). Incluso algunos trabajos mencionan la idea de que los SOM capturan algunos de los principios básicos de organización del cerebro (Kohonen, 2006, 2013). En este sentido, el esquema de autoorganización tiene cabida en las ideas propuestas por (Meyer y Damasio, 2009) para la creación de una estructura que recree algunas funcionalidades de la corteza cerebral y la integración multimodal.

2. El SOM es un método de proyección, el cual, mapea datos de un espacio de alta dimensionalidad a un espacio de baja dimensionalidad, y un método de agrupación tal que los ejemplos similares tienden a ser mapeados a neuronas cercanas. Este funcionamiento permite extraer las características esenciales del flujo de entrada, encontrando el ordenamiento de baja dimensionalidad subyacente a los datos. Es decir, permite la captura de las regularidades y redundancias de los datos presentados en su entrada.

3. El SOM es un modelo de aprendizaje no supervisado y un esquema adaptativo de representación de conocimiento. Los formalismos de representación de conocimiento GOFAI, son estáticos y las relaciones de referencia a los elementos son determinadas por un humano. En vez de ello, los SOM permiten extraer las relaciones de referencia directamente del flujo sensorial originado por la interacción del cuerpo del agente con su entorno. Estas relaciones crean una representación cimentada del mundo, en concordancia con la escuela de la robótica cognitiva.

3.3. Asociación entre mapas

En trabajos recientes se ha reportado la asociación entre SOMs de diferentes modalidades, tanto en el modelado de la conexión entre diferentes regiones cerebrales, como en el modelado de la función psicológica. Por ejemplo en el trabajo de Westerman et al. (2003) la asociación entre mapas de vocalización y audición es utilizada para modelar la emergencia de categorías vocales. En los trabajos de Li, et al. (2004) y Li, et al. (2007) se encontraron la claves sobre la edad del desarrollo léxico en infantes siguiendo un modelado similar basado en mapas. En Mayor et al. (2010) se utilizó una asociación entre los mapas visual y auditivo para determinar la respuesta taxonómica en el aprendizaje temprano

de palabras. En el trabajo de Luciw et al. (2010) se usan conexiones *top-down* en una red de aprendizaje similar para problemas de reconocimiento visual estático. En Morse, et al. (2010) se utiliza la integración de distintos mapas modales sensoriales y motrices a través de una red dinámica con aprendizaje hebbiano para construir un sistema de adquisición de significado semántico. También en este mismo contexto se tiene la investigación de (Lallee et al., 2013) donde, utilizando un esquema similar, se propone un mecanismo para realizar imagineria mental en un agente artificial.

En nuestro trabajo, creamos la asociación entre SOMs de diferentes modalidades mediante redes dinámicas entrenadas con una *regla de aprendizaje hebbiana* (Hebb, 1949). Dicha regla menciona que:

> "Cuando un axón de la célula A esta suficientemente cerca para excitar a una célula B y repetidamente o persistentemente contribuye al disparo de ésta, algunos procesos de crecimiento o cambios metabólicos tienen lugar en una o ambas células tal que la eficiencia de A, con relación a su participación como excitadora de B, se incrementa." (Hebb, 1949, p. 62)

En este sentido la regla hebbiana establece que la conexión entre neuronas artificiales se refuerza de acuerdo a la activación de las neuronas que participan en la conexión. En nuestro modelo utilizamos una regla hebbiana positiva para modular las conexiones entre nodos de diferentes mapas.

En forma matemática esta regla es expresada en las formulas siguientes:

$$w_{ij}^{t+1} = w_{ij}^{t} + \Delta w_{ij} \tag{3.7}$$

$$\Delta w_{ij} = \alpha u_i u_j \tag{3.8}$$

donde w_{ij} es el peso de la conexión entre el nodo j y el nodo i, α es la tasa de aprendizaje, u_i es la activación del nodo i mientras u_j es la activación del nodo j. La formula 3.7 expresa el cambio o actualización de los pesos sinápticos, mientras que la fórmula 3.8 presenta el cálculo de la magnitud de ese cambio.

Capítulo 4

SOIMA Básico

4.1. Entrenamiento General

El esquema básico de la arquitectura SOIMA consiste de dos SOM: S y M, correspondientes a las modalidades sensorial y motriz del agente respectivamente. Ambas modalidades se conectan, mediante conexiones dinámicas con aprendizaje hebbiano, con un mapa superior en el que se forma una *representación multimodal* (MMR por sus siglas en ingles "Multi-Modal Representation").

En la Figura 4.1 se presenta el esquema básico SOIMA con la integración de las dos clases principales de modalidades: las sensoriales y las motrices. Las modalidades sensoriales se conforman de los datos provenientes de los distintos sensores distribuidos en el cuerpo del agente. Dichas modalidades se encargan de proveer la información necesaria acerca del estado del entorno y del propio cuerpo. Las modalidades motrices, por otra parte, se relacionan con los diferentes actuadores en el cuerpo del agente. Sobre estas modalidades es que toman efecto los comandos motrices generados por el agente para completar sus objetivos. Cada SOM es entrenado de manera independiente utilizando el procedimiento descrito en la sección 3.2.1 de acuerdo a datos provenientes de la modalidad correspondiente.

Una vez que los SOM contienen la codificación de la información modal, se crean las asociaciones entre ellos a fin de crear una integración multimodal. La idea del proceso de asociación consiste en la modulación hebbiana de una red de conexiones entre el mapa MMR superior y cada SOM modal. Cada neurona del MMR superior esta conectado con todos los neuronas de los SOM modales.

El procedimiento de asociación toma lugar como sigue. Los dos mapas S y M son alimentados con los datos sensoriales y motrices generados en un mismo evento durante la interacción del agente con el entorno. Cuando se presenta la información sensorial y motriz a los SOM, se activan las respectivas neuronas ganadoras en S y en M. El patrón de entrada al mapa MMR son las coordenadas, en su respectivo SOM, de las neuronas ganadoras. El referido patrón

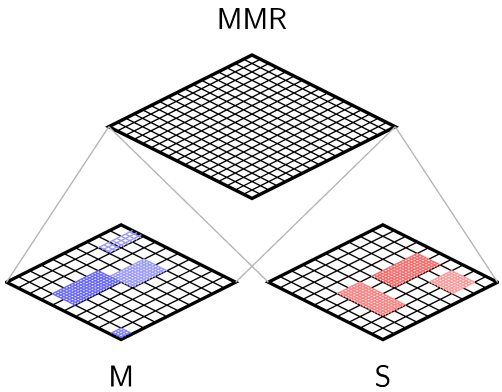

Figura 4.1: *Estructura básica de la arquitectura de modelos internos autoorganizados (SOIMA). Se muestran dos mapas modales correspondientes a* M *y* S*. El mapa superior integra las modalidades codificando el esquema sensorimotriz en una representación multimodal (*MMR*).*

activa a su vez una neurona ganadora en el MMR. Finalmente, la modulación hebbiana es aplicada a la conexiones entre las neuronas activadas en los SOM modales S y M y aquel activado en el MMR. De esta manera, a través del mecanismo hebbiano, se construye la integración y representación multimodal del evento en el mapa MMR. Una vez que el sistema ha sido entrenado, la asociación resultante permite la recuperación de todas las modalidades aun cuando sólo alguna o algunas de ellas estén disponibles. Cabe mencionar que inicialmente todas las conexiones entre neuronas de distintos mapas se establecen a un valor de cero.

4.2. Modelos Internos y SOIMA

Por otra parte, una de las propiedades importantes que nos ofrece la arquitectura es la de codificar mediante un mismo mapa SOM la información modal en diferentes instantes de tiempo. Por ejemplo en la modalidad sensorial al tiempo actual t y al tiempo siguiente $t+1$. La información de estos diferentes instantes temporales es codificada a través de dos distintas conexiones dinámicas entre el mapa S y el MMR.

En la Figura 4.2 se muestra un ejemplo de asociación multimodal entre los tres mapas S, M y MMR. En dicha figura se pueden observar las neuronas ganadoras de cada SOM y las asociaciones que se realizan mediante el aprendizaje hebbiano. Particularmente podemos observar que el mapa S tiene dos neuronas activas, las cuales corresponden a las entradas sensoriales al tiempo actual y al tiempo siguiente. Cada una de estas dos neuronas se conectan mediante su propia conexión dinámica a una misma neurona del MMR. En este sentido el sistema entrenado asocia una tripleta formada por la situación sensorial al tiempo actual, un comando motriz y la situación sensorial al tiempo siguiente relacionada con las dos anteriores. De acuerdo a esto podemos pensar que cada neurona en el MMR codifica una experiencia sensorimotriz específica del agente. Además, el sistema crea un esquema sensorimotriz para un comportamiento particular.

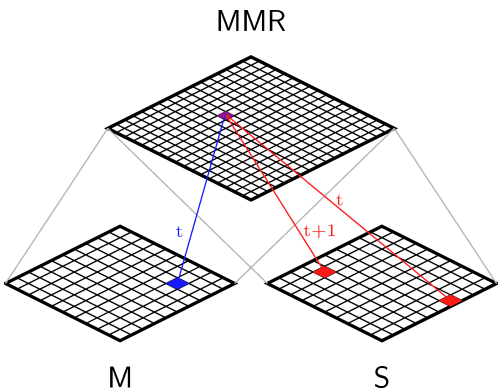

Figura 4.2: *Ejemplo de asociación multimodal sobre neuronas activas en el esquema básico SOIMA. En la imagen se muestra la codificación de dos diferentes instantes de tiempo t y $t+1$ en el mapa sensorial.*

Este mismo esquema se puede extrapolar para integrar un conjunto de instantes temporales, en otras palabras, no hay restricción en tener un solo mapa SOM con k-conexiones temporales diferenciadas t,$t+1$,...,$t+k-1$, en donde todas se pueden activar o desactivar de acuerdo a las necesidades de la tarea cognitiva.

La presente investigación utiliza la arquitectura como sustrato de codificación de los modelos internos. Es a través del entrenamiento de SOIMA y de

la integración multimodal suscitada que se construyen estos modelos internos.

En caso de que se requiera instanciar el modelo directo o predictor sería necesario proveer a SOIMA la entrada sensorial al tiempo actual S_t y el comando motriz M_t que sería aplicado. Estas entradas modales producen activaciones en sus respectivos SOM's S y M, posteriormente se propagan dichas activaciones a través de las conexiones dinámicas hasta el MMR , finalmente la activación del MMR es propagada hacia el mapa S para producir la salida S^*_{t+1}. Dicha salida S^*_{t+1} es la predicción que el sistema produce de acuerdo al estado sensorial que se alcanzaría de efectuar el comando motriz M_t partiendo del estado sensorial S_t. Durante la propagación de las señales en SOIMA, podemos pensar en la activación del MMR como la recreación de la representación multimodal del evento.

Si, por el contrario necesitamos producir el comando motriz M_t necesario para alcanzar un estado sensorial deseado S_{t+1}, es necesario que SOIMA actúe como un modelo inverso o controlador. En este sentido las entradas requeridas son dos entradas sensoriales, donde una de ellas corresponde al estado sensorial actual S_t y la otra entrada corresponde al estado sensorial que se desea alcanzar S_{t+1}. Dichas entradas son presentadas al mapa S para producir las activaciones correspondientes, estas disparan la activación del MMR, el cual a su vez activa un nodo en el mapa M. Este nodo contiene el comando motriz necesario para producir el cambio de S_t a S_{t+1}.

4.3. Propiedades SOIMA

Una de las principales ventajas de SOIMA reside en su funcionalidad bidireccional, que le permite desempeñarse indistintamente como modelo directo y modelo inverso dependiendo de las entradas que sean alimentadas al sistema. Es decir, que el sistema ha integrado el esquema sensorimotriz de tal manera que es ahora independiente de la dirección del flujo de información modal. Esto representa un avance importante en la representación multimodal, la cual al alcanzar la generalidad carece de dirección y sólo cuando hay ciertos estímulos presentes es cuando se hace necesario un carácter direccional del flujo de información.

Por otro lado, el MMR permite que la bidireccionalidad sea funcional todo el tiempo. En otras palabras, cualquier modelo (MI o MD) pueden ser fácilmente implementados simplemente al instanciar las entradas correspondientes para la funcionalidad requerida. De esta manera, ambos modelos internos son

codificados en el mismo sustrato, permitiendo además el aprendizaje conjunto de ambos modelos.

Aun más, SOIMA permite la construcción de pares MI-MD acoplados sin necesidad de entrenarlos independientemente. Para realizar un acoplamiento de este tipo se crea una instancia de un MI, posteriormente la salida motriz de este puede ser usada como entrada de una instancia del MD para predecir el estado sensorial de ejecutar el comando motriz. Ambas instancias son creadas sobre el mismo esquema ya entrenado y constituyen un acoplamiento MI-MD. Así, varios acoplamientos MI-MD pueden ser instanciados secuencialmente para diferentes instantes de tiempo, esto puede ser sumamente útil para realizar predicciones de largo plazo y para construir un proceso de simulación.

Es importante hacer notar que la representación multi-modal no esta construida en el mismo sentido de las representaciones abstractas definidas por el programador del sistema como en la corriente clásica de la Inteligencia Artificial, sino que son *representaciones cimentadas* en la interacción del cuerpo del agente con todas sus particulares capacidades motrices y sensoriales con el entorno en el que se desenvuelve. Esto permite que la exploración este regulada por las capacidades únicas e individuales del cuerpo del propio agente, lo que hacen a dichas representaciones particularmente útiles para el desempeño coherente del agente, y al mismo tiempo lo dotan con un sentido de percepción subjetiva.

También cabe destacar la capacidad de la arquitectura de realizar aprendizaje en linea, es decir, que mientras se esta utilizando la arquitectura esta es capaz de ir adquiriendo nuevo conocimiento a fin de mejorar su desempeño de manera constante. Esta capacidad se consigue a través de la actualización de las redes dinámicas de inter-conexión de los SOM, con lo que el sistema se puede adaptar a las situaciones desconocidas que se vayan presentando como entrada al sistema. Esta característica cobra relevancia si pensamos que los sistemas cognitivos no son sistemas estáticos, es decir, que una vez que son diseñados se desempeñan perfectamente en su nicho designado. En realidad los sistemas cognitivos deben ser sometidos a un desarrollo continuo a través de la interacción con su entorno. La cognición, al menos de forma natural, no es el resultado de la genética por si sola (Oyama, 2000), sino que resulta de la interacción de la genética (en el caso de los sistemas artificiales no evolucionados, del diseño de los algoritmos) y el medio ambiente. De tal manera que las nuevas conductas, habilidades y capacidades surgen durante la vida útil del sistema. En varios casos, este desarrollo sigue necesariamente una secuencia donde la adquisición de ciertas habilidades es un requisito previo de los que

emergen posteriormente. Estas características serán ilustradas en los casos de estudio presentados a continuación.

4.4. Control de movimientos sacádicos para una cámara PTZ

Como primer caso de estudio, para mostrar el desempeño de la arquitectura SOIMA, se propone el diseño e implementación de una tarea de control sacádico para un agente artificial.

Los *movimientos sacádicos* son movimientos oculares rápidos (Leigh et al., 1999), los cuales tienen como fin proyectar la imagen del área visual de interés en la parte más sensible de la retina, llamada fóvea.

El objetivo de este experimento es adquirir un esquema sensorimotriz que permita a un agente artificial realizar movimientos sacádicos sobre su sistema de visión. En el agente artificial, el sistema oculo-motriz esta constituido por una cámara montada sobre una unidad "pan-tilt" donde *pan* se refiere a los movimientos horizontales y *tilt* a los movimientos verticales.

Interesa crear un sistema que le permita al agente artificial aprender la relación que existe entre los movimientos de su cámara y el cambio sensorial percibido por ella.

Este esquema sensorimotriz, una vez adquirido, desempeñará una doble función: primero, servirá como mecanismo para sugerir el comando motriz sacádico requerido para centrar en la imagen algún estímulo sobresaliente. Segundo, podrá predecir las consecuencias sensoriales de efectuar dicho comando motriz, esta predicción tendrá la función de actuar como un mecanismo para afinar el comando motriz.

Cabe mencionar la investigación de Kaiser, et al. (2013) sobre el problema de la correspondencia en sistemas de cámaras estéreo. En dicho trabajo se presenta un modelo de control sacádico basado en modelos internos y se afirma que tratar el problema de las predicciones de imágenes es algo altamente complejo debido a la alta dimensionalidad de la entrada, por esto en su propuesta no se realizan predicciones, si no que se hacen mapeos inversos sobre la imagen de salida hacia la imagen que tienen como entrada. Por nuestra parte, el sistema que proponemos si trata el problema de predicción de imágenes de alta dimensionalidad.

4.4.1. Plataforma y entorno experimental

Como sistema hardware se usó una cámara PTZ (pan-tilt-zoom) marca Canon modelo VB-C60, que cuenta con una resolución de 0.01 grados en los movimientos pan y tilt.

A fin de acotar el problema situamos la cámara a 35 cm de distancia de una pared blanca con un único estímulo relevante (circulo rojo de 1cm de diámetro) (Fig. 4.3).

Figura 4.3: *Entorno experimental del experimento de control sacadico, constituido por la cámara canon PTZ ubicada a 35 cm de distancia frente a una pared blanca con un solo estímulo relevante.*

4.4.2. Estructura SOIMA

El sistema propuesto utiliza una imagen capturada por la cámara como entrada y hace uso de ambos modelos internos acoplados MD-MI a fin de proporcionar el comando motriz necesario para colocar algún estímulo presente en la imagen en alguna posición especifica. En la Fig. 4.4 podemos ver el diagrama del sistema propuesto.

En la primera parte de este acople, la entrada S_t representa la entrada sensorial visual actual, es decir, la imagen con el estímulo presente en alguna posición arbitraria. La entrada S_{t+1} representa el estado sensorial visual deseado, es decir, la imagen con el estímulo en la posición deseada. Con estás entradas el modelo inverso sugiere el comando motriz M_t que permite al sistema de visión el cambio sensorial deseado.

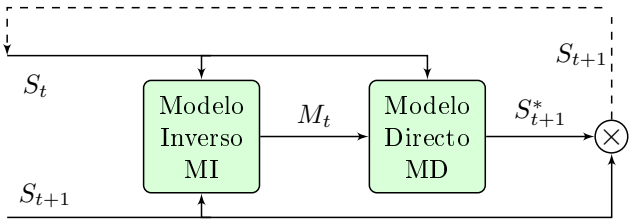

Figura 4.4: *Control sacádico*

En este experimento se consideraron diferentes mapas para los estados sensoriales al tiempo actual S_t y al tiempo siguiente S_{t+1}. En experimentos subsecuentes ya no se utilizaron mapas diferentes pues se considero que en términos prácticos se obtenían los mismos resultados con un solo mapa, lo que resulta en una forma mas compacta y elegante de realizar la integración multimodal.

Posteriormente este comando motriz M_t junto con la imagen S_t son alimentados al modelo directo para predecir el resultado sensorial S^*_{t+1} de aplicar el comando motriz sobre el sistema. Esta imagen S^*_{t+1} se compara con S_{t+1} para obtener el error de la predicción. Este error es utilizado para decidir si es necesario volver a ejecutar el ciclo MI-MD esta vez alimentando como entrada la predicción S^*_{t+1} en lugar de S_t de manera que el sistema sugiera un segundo movimiento que permita centrar el estímulo con mayor precisión. Este mecanismo proporciona la secuencia de comandos motrices que se requiere ejecutar en el sistema de movimientos de la cámara para centrar el estímulo.

La implementación de los modelos internos mediante otros métodos de aprendizaje conlleva serias limitaciones en cuanto al uso de imágenes, pues estas aumentan considerablemente la dimensionalidad del problema así como la complejidad para encontrar las regularidades en las entradas que permitan aprender el esquema sensorimotor. El uso de nuestra arquitectura permite lidiar con estas limitaciones.

Finalmente, el esquema SOIMA utilizado se muestra en la Fig. 4.5. Como una primera aproximación se usó un mapa individual para codificar tanto la entrada correspondiente al estado sensorial actual, así como para codificar el

estado sensorial siguiente. Es por ello que se utilizó un mapa $\mathsf{S_t}$ de 30×30 neuronas para S_t y otro mapa independiente $\mathsf{S_{t+1}}$ de 30×30 neuronas para S_{t+1}. Para codificar M_t se usó un mapa M de 40×40 neuronas y finalmente para codificar la representación multimodal se usó un mapa MMR de 40×40 neuronas.

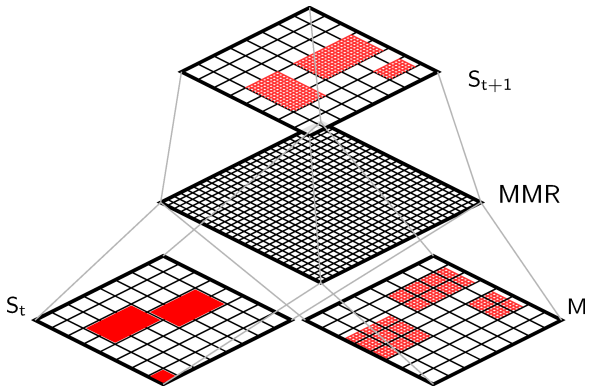

Figura 4.5: *Esquema de SOIMA utilizado en la tarea de control sacadico para la cámara pan-tilt.*

4.4.3. Entrenamiento de la red SOIMA

Para realizar el entrenamiento es necesario determinar como se forman los patrones de entrada al sistema.

Cada patrón esta compuesto por el estado sensorial al tiempo actual S_t, el comando motriz M_t y la estado sensorial al tiempo siguiente $S_t + 1$. En el presente caso de estudio los estados sensoriales S_t y S_{t+1} se refieren a imágenes capturadas por la cámara, en tanto que el comando motriz M_t esta definido como un cambio de orientación en el sistema de movimientos de la cámara (ΔPan,ΔTilt).

Preprocesamiento de la entrada sensorial

Para construir la imagen que constituye el estado sensorial se realizan dos etapas de preprocesamiento. En la primer etapa se construye una ima-

gen fovealizada a partir de la imagen original de la cámara de 640x480 píxeles. Para la segunda etapa se construye un mapa de rasgos sobresalientes.

En cuanto a la construcción de la imagen fovealizada de la primera etapa se utilizó un mapeo foveal radial (Kaiser et al., 2013) similar al mapeo log-polar (Traver et al., 2010), en donde la resolución es alta en el centro de la imagen y baja hacia la periferia. Este mapeo emula el efecto de la retina del ojo en primates que tienen una mayor densidad de células fotoreceptoras en una pequeña región llamada fovea (Daniel et al., 1961).

El mapeo foveal radial esta modelado bajo las siguientes ecuaciones:

$$\alpha_{out} = \arctan(y_{out}, x_{out}) \tag{4.1}$$

$$r_{out} = \sqrt{x_{out}^2 + y_{out}^2} \tag{4.2}$$

$$\alpha_{in} = \alpha_{out} \tag{4.3}$$

$$r_{in} = ((\lambda - 1) * r_{out}^{\gamma} + r_{out}) \tag{4.4}$$

Donde (α_{in}, r_{in}), (α_{out}, r_{out}) denotan las coordenadas polares de la imagen de entrada y la imagen de salida respectivamente, λ es el factor de escala de 0.5 y γ es el factor de distorsión radial de 3.0. El algoritmo de fovealización entrega una imagen de 320x240.

En nuestro diseño esto cumple una función especial ya que cuando algún estímulo se encuentra cerca de la parte central de la imagen (fovea) un cambio pequeño en pan o tilt corresponde a un cambio grande de posición del estímulo en la imagen. Esto permite detectar con mayor precisión la posición del estímulo cuanto más próximo se encuentra a la región central de la imagen y como consecuencia realizar la tarea de centrar un estímulo con mayor precisión.

La función de la segunda etapa de preprocesamiento es facilitar la identificación de *estímulos sobresalientes* en la imagen capturada por la cámara. Esta tarea se lleva a cabo mediante la construcción de un mapa de rasgos sobresalientes[1].

El mapa de rasgos sobresalientes esta sustentado en la biología del sistema de visión humano, específicamente en la capacidad de percibir intensidad luminosa, color y orientación de los estímulos visuales.

[1] Los rasgos sobresalientes son una métrica que define a estímulos importantes como valores estadísticos atípicos. Para que un estímulo se vuelva sobresaliente es necesario que al menos uno de sus atributos visuales sea único o por lo menos raro en la escena visual entera (Itti et al., 2005).

Los pioneros en el computo de rasgos sobresalientes y su integración en un mapa como una representación del entorno fueron Itti et al. (1998). En su trabajo implementaron el mapa de rasgos sobresalientes como una manera de hacer un análisis rápido de imágenes.

En la Fig. 4.6 se muestra el calculo de los rasgos sobresalientes sobre una imagen arbitraria donde las zonas en tonos de gris indican las partes mas relevantes de la escena, cuanto más claro es el tono de gris más sobresaliente es la zona.

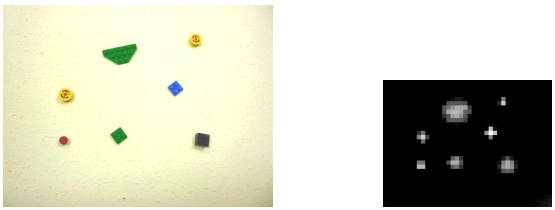

(a) (b)

Figura 4.6: *Imagen de rasgos sobresalientes producida a partir de una imagen arbitraria; (a) Imagen arbitraria de* 320×240 *píxeles, (b) Imagen producida de rasgos sobresalientes de* 40×30 *píxeles.*

El procedimiento para calcular el mapa de rasgos sobresalientes es el siguiente:

- La imagen se separa en 3 principales características, a saber, la intensidad, el color y la orientación.
- Se reduce el tamaño de las imágenes de características a diferentes escalas.
- Posteriormente, se computa la diferencia entre las distintas escalas usando como base las imágenes de 40×30 píxeles y se realiza una normalización gaussiana para transformar las imágenes en mapas de visibilidad (conspicuity maps).
- Finalmente, se integran como un promedio en una sola imagen de rasgos sobresalientes (saliency map).

En esta etapa la imagen se reduce a 40×30 píxeles. En la Fig. 4.7 podemos ver el preprocesamiento de una imagen típica del estado sensorial.

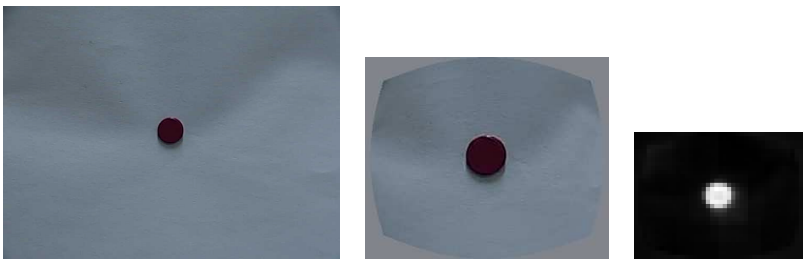

(a) (b) (c)

Figura 4.7: *Preprocesamiento de la imagen de entrada para producir una imagen fovealizada de rasgos sobresalientes; (a) imagen original de* 640×480 *píxeles, (b) imagen fovealizada de* 320×240 *píxeles, (c) imagen de rasgos sobresalientes de* 40×30 *píxeles.*

Construcción del comando motriz

En nuestro sistema, un comando motriz m es un cambio de orientación (en grados) de la cámara, en el eje horizontal y en el eje vertical. El cambio, entre dos posiciones de la cámara, depende de la resolución del espacio motriz del sistema. Dicha resolución en nuestro caso fue construida, de manera similar al procesamiento visual, utilizando un mecanismo de fovealización.

Este proceso de *fovealización motriz* consistió en una resolución variable de los movimientos pan y tilt con referencia al centro del espacio motriz. Donde se contó con una mayor resolución motriz en el centro que en la periferia.

El espacio motriz se delimitó buscando que el estímulo visual permaneciera dentro del campo de visión (FOV, por sus siglas en ingles de *Field of view*) de la cámara. El espacio motriz determinado fue de $Pan = [-10^o, 10^o]$ y $Tilt = [2{,}4^o, 17{,}4^o]$ (Fig. 4.8).

Las ecuaciones que describen el procesamiento de fovealizacion son las ecuaciones del mapeo foveal radial descritas en Ec. (4.1), (4.2), (4.3) y (4.4), pero sustituyendo las coordenadas x y y por los valores de Pan y $Tilt$

Para visualizar la fovealización del espacio motriz, se construyo una imagen de resolución motriz (I_{RM}) a partir de un total de 20,000 imágenes tomadas con la cámara en distintas posiciones aleatorias del espacio motriz fovealizado. Para construir I_{RM} se realizó el siguiente procedimiento:

1. Se creo una matriz I_{rm} de ceros de $40{\times}30$ elementos.

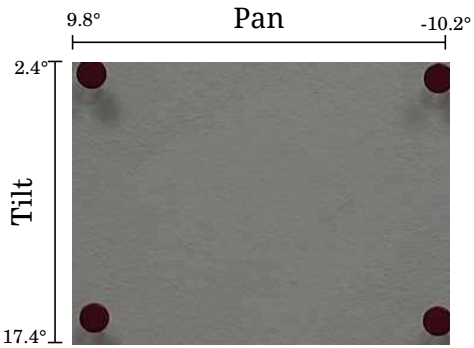

Figura 4.8: *Rangos de movimiento de la cámara en los ejes horizontal (Pan) y vertical (Tilt) con el estímulo visual dentro de su FOV; Se muestran las cuatro posiciones del estímulo sobrepuestas en una sola imagen donde se pueden percibir que el rango es de [-10.2,9.8] para movimientos en Pan, en cuanto a Tilt el rango resultante es de [2.4,17.4].*

2. Para cada una de las 20,000 imágenes:

   - Se calculó la imagen de rasgos sobresalientes.
   - Se determinaron las coordenadas p_x y p_y del píxel p correspondiente al centro de masa del estímulo visual relevante.
   - Se incremento en 1 el elemento de la matriz I_{rm} con coordenadas (p_x,p_y).

3. Finalmente se convirtió la matriz I_{rm} en una imagen (I_{RM}) en escala de grises.

Este proceso dio origen a una imagen de intensidades donde el valor de cada píxel es proporcional al número de veces que el estímulo esta presente en cada ubicación.

La imagen I_{RM} se puede observar en la Fig. 4.9. Como se puede apreciar, la densidad más alta del estímulo visual sobre las posiciones de la cámara se encuentra en la región central de la imagen.

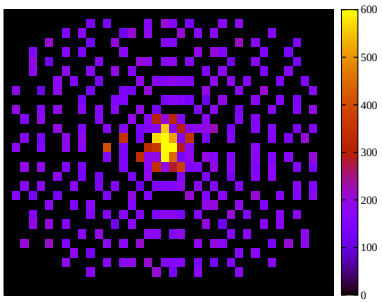

Figura 4.9: *Distribución del estímulo visual sobre 20,000 posiciones aleatorias de la cámara con resolución motriz fovealizada.*

Entrenamiento de los SOM

Los mapas modales se entrenaron individualmente utilizando 20,000 patrones recolectados aleatoriamente con la siguiente estructura:

- S_t: Se formó a partir de la imagen de rasgos sobresalientes de 30×40 píxeles mediante la cual se construyó un vector de 1200 valores normalizados de 0 a 1.
- S_{t+1}: Se formó de la misma manera que S_t pero utilizando otra posición de la cámara.
- M_t: Estuvo constituido por 2 valores (ΔPan, ΔTilt) que representan el cambio de orientación sobre el eje vertical y el eje horizontal respectivamente. Estos cambios se calcularon de acuerdo a la diferencia de orientación entre la posición de la cámara en el tiempo actual y el tiempo siguiente. Esto se puede apreciar en las siguientes ecuaciones:

$$\Delta Pan = Pan_t - Pan_{t+1} \tag{4.5}$$

$$\Delta Tilt = Tilt_t - Tilt_{t+1}. \tag{4.6}$$

  donde tanto ΔPan como ΔTilt se normalizaron de 0 a 1. En este sentido un valor de 1 representa el mayor cambio posible en sentido positivo sobre el eje correspondiente y mientras un valor de 0 representa el mayor cambio posible en el otro sentido. Un valor de 0.5 representa ausencia de movimiento sobre ese eje.

Después de entrenar los SOM, cada neurona de los mapas correspondientes al estado sensorial (S_t y S_{t+1}) codifica una imagen con un estímulo en alguna posición y las neuronas contiguas codifican imágenes que se parecen entre si. Una región del mapa S_t después del entrenamiento se puede apreciar en la Fig. 4.10. A fin de construir esta representación gráfica del SOM, ha sido necesario organizar los valores de cada vector prototipo en matrices de 40×30, las cuales han sido convertidas en imágenes en escala de grises.

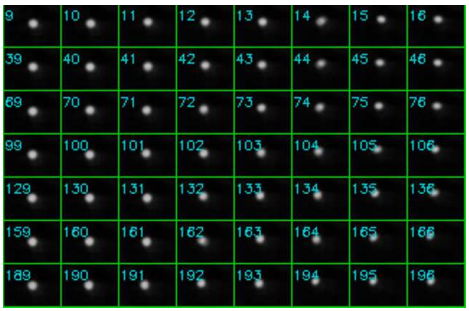

Figura 4.10: *Fragmento del mapa S_t entrenado. Se indica el número correspondiente a cada neurona representada. Se puede observar la representación de cada neurona como la imagen de rasgos sobresalientes que representa los valores de su vector prototipo, así como también la similitud entre neuronas contiguas.*

Antes de mencionar los experimentos del control desarrollado hay un par aspectos del funcionamiento práctico de la arquitectura a considerar.

La primera es que existen ocasiones en que SOIMA no puede encontrar una conexión entre los SOM modales y el MMR. Digamos que SOIMA se esta desempeñando como modelo directo. Al presentar la información modal a los mapas S_t y M se produce activación en las neuronas s y m en los mapas correspondientes. SOIMA busca a cual de las neuronas del mapa MMR activan ambas neuronas s y m. En algunas ocasiones no hay ninguna neurona en el MMR que sea activada de manera conjunta por ambas neuronas. Cabe aclarar que aun cuando la conexión existe entre cada par de neuronas, sólo aquellas conexiones distintas de cero pueden transferir la activación de una neurona a otra.

Para resolver esta situación, para activar una neurona en el MMR no sólo se tomó en cuenta a las neuronas s y m, que son las de mayor activación,

sino también se consideró en orden descendente de activación a otras neuronas activas en los SOM S y M. Esto incrementa la posibilidad de que las entradas en los SOM modales activen al MMR, sin embargo tiene la desventaja que entre más se prolonga la búsqueda más imprecisa es la salida de la predicción. En nuestro caso la búsqueda esta acotada sobre un número limitado de neuronas en cada SOM modal. Este mecanismo es una técnica original que no ha sido considerada en otras implementaciones y ha ayudado a lidiar con el problema de la alta dimensionalidad del espacio de entrada inherente al trabajo con imágenes.

La segunda consideración se refiere a que independientemente de como sea utilizada la arquitectura SOIMA (MI o MD), al realizar la propagación del MMR hacia algún SOM es probable que se produzca la activación de dos o mas neuronas. En nuestro caso, consideramos que la neurona activa es aquella que tenga la mayor fuerza de conexión al MMR.

4.4.4. Experimentos y resultados

Como ya se menciono anteriormente una parte importante de la arquitectura es la capacidad de aprender en linea las conexiones hebbianas. Inicialmente el sistema no cuenta con ninguna asociación hebbiana entre los mapas, es decir que todas las conexiones tienen un valor de 0, por lo tanto no se puede sugerir un comando motriz que permita centrar el estímulo mediante el modelo inverso. Por lo que se ha provisto al sistema de un mecanismo de balbuceo motriz, el cual genera un comando motriz M_t aleatorio cuando al sistema no le es posible producirlo. Posteriormente este comando se ejecuta y se obtiene la imagen S_{t+1}. Esta información se integra en las conexiones entre los SOM usando el aprendizaje hebbiano en linea.

Este aprendizaje va incrementando paulatinamente el conocimiento sensorimotriz de los movimientos sacádicos, lo cual disminuye el uso del balbuceo motriz y aumenta el uso del sistema SOIMA. En la Fig. 4.11 se puede apreciar el aumento del porcentaje de uso de SOIMA, en donde al comenzar el funcionamiento el uso es prácticamente nulo, mientras que después de 7500 patrones el uso del sistema es de casi 100 %.

Por otra parte, el aprendizaje del esquema sensorimotriz también disminuye el error al centrar el estímulo en la escena visual. Es pertinente aclarar que dicho error se define como la distancia euclidiana (en píxeles) entre el píxel central de la imagen y el centro de masa del estímulo en la imagen S_{t+1} después de ejecutar el movimiento. En la Fig. 4.12 podemos apreciar el error calculado

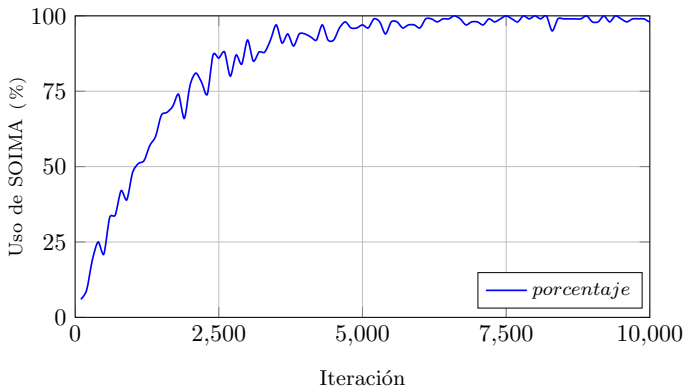

Figura 4.11: *Porcentaje de uso de SOIMA para la tarea de control sacádico.*

sobre el aprendizaje del sistema, donde se observa que después de 5000 patrones el error se estabiliza en un valor de alrededor de 10 píxeles. Cabe mencionar que el error se obtuvo de la imagen original sin fovealizar de 640×480 píxeles, aun cuando el proceso que SOIMA lleva a cabo se realizó con la imagen de rasgos sobresalientes de 40×30 píxeles. Esto conlleva a una prueba mas rigurosa de SOIMA, pues amplifica la magnitud del error.

Adicionalmente al aprendizaje hebbiano en linea ya mencionado, nuestro sistema cuenta con otros criterios para aplicar dicho aprendizaje sobre las conexiones entre SOM. Estos criterios solo son utilizados cuando el comando motriz es sugerido por el sistema, es decir cuando el sistema ya contiene algunas asociaciones multimodales y es capaz de actuar como MI o MD.

Los otros criterios para realizar el aprendizaje en-linea son:

- Cuando el error entre la imagen predicha y la imagen real después de ejecutar el comando motriz es más grande que un umbral. En estos casos, se utiliza la imagen real como S_{t+1} y se ejecuta el aprendizaje en linea. Esto permite crear nuevas asociaciones y mejorar por consiguiente las predicciones del modelo directo.

- Cuando la arquitectura sugiere una secuencia de dos movimientos sacádicos para alcanzar la posición deseada. En este caso se integran los dos movimientos en un solo y utilizando éste es que se realiza el aprendizaje

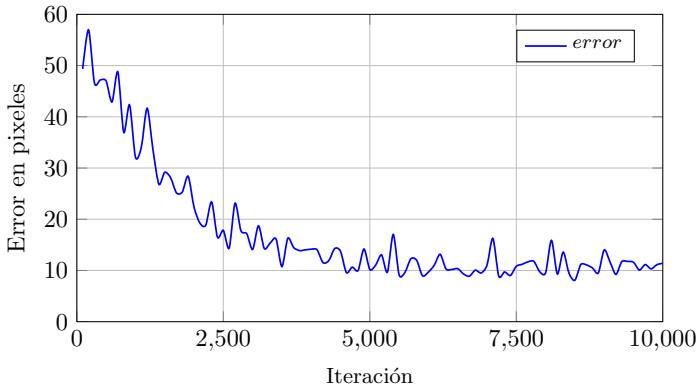

Figura 4.12: *Error en píxeles de la posición del centro de masa del estímulo en la imagen al centro de esta.*

en-linea. Esto ayuda a que el modelo inverso sugiera un solo comando motriz que permita alcanzar la posición deseada.

- En caso que después de ejecutar en la cámara la secuencia de comandos motrices aun hay un error mas grande que cierto umbral entre la salida deseada y la real, entonces se calcula otra secuencia de comandos motrices y se ejecuta en el sistema, posteriormente se integran las dos secuencias de comandos motrices y se agrega esta información nueva en el sistema como si se tratara de una sola ejecución.

En la Fig. 4.13 podemos ver las trayectorias de los movimientos sacádicos de la cámara antes y después del aprendizaje en-linea en dos situaciones iniciales iguales. En cada imagen se muestra la trayectoria del estímulo durante las sacadas, en donde el circulo indica la posición deseada del estímulo y la linea muestra la trayectoria. En la Fig. 4.13(a) podemos ver las sacadas del sistema antes del aprendizaje en linea, donde se observa que son necesarios dos movimientos sacádicos para centrar el estímulo. Por otra parte en la Fig. 4.13(b) se muestra el desempeño del sistema con la misma ubicación del estímulo después del aprendizaje, en donde solo se requiere un movimiento sacádico para centrar el estímulo.

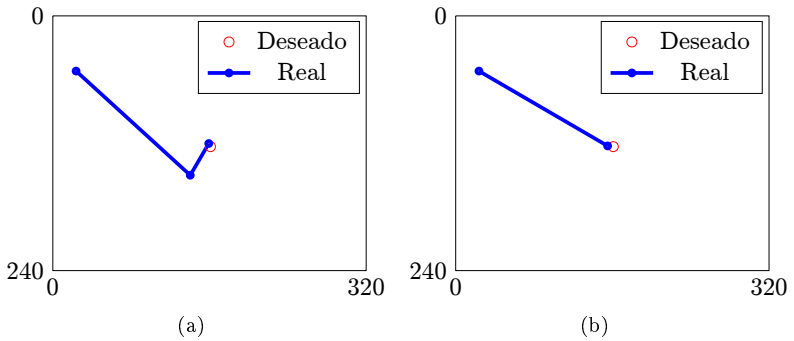

Figura 4.13: *(a) Trayectoria de los movimientos sacádicos antes del aprendizaje en linea; (b) Trayectoria de los movimientos sacádicos después de realizar el aprendizaje.*

Control sacádico

En este acople de modelos internos se proporciona como entrada S_t y S_{t+1} deseado y el sistema devuelve el comando o comandos motrices necesarios para alcanzar la S_{t+1} deseada, así como también proporciona un S^*_{t+1} predicho a fin de calcular el error y de ser necesario calcular un segundo comando motriz de afinación.

En nuestro caso deseamos que el sistema centre el estímulo en la imagen, sin embargo debido a que el entrenamiento codifica todo el espacio de entrada, es posible darle una localización especifica donde se quiere que se encuentre el estímulo en la imagen después de mover la cámara. A partir de un repositorio de imágenes tomadas con la cámara es que se obtiene la S_{t+1} deseada.

Un ejemplo típico de prueba lo podemos apreciar en la Fig. 4.14. En este ejemplo se llevan a cabo dos pasos de procesamiento:

- *Movimiento sacádico de aproximación.* Se registra la imagen actual de la cámara y se procesa de acuerdo a las zonas de rasgos sobresalientes para formar a S_t, también se alimenta la imagen deseada S_{t+1} con la zona relevante en el centro. Estas entradas pasan por el modelo inverso y generan un conjunto de sugerencias para el comando motriz M_t. Dichas sugerencias son aplicadas junto con S_t al modelo directo para generar la predicción S^*_{t+1} para cada comando M_t. Las predicciones son compara-

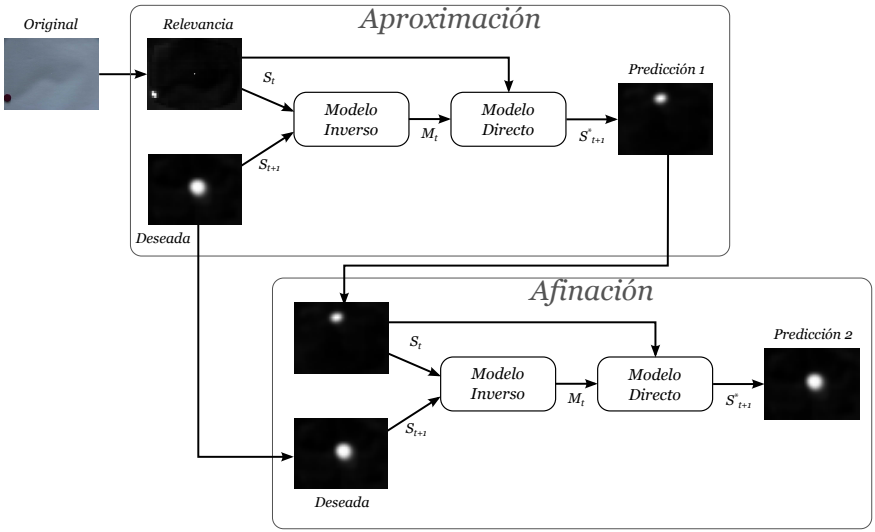

Figura 4.14: *Ejemplo típico de ejecución*

das con el S_{t+1} deseado para computar el error. Finalmente el comando motriz que produce el menor error es el que se ejecutará en la cámara.

- *Movimiento sacádico de afinación.* Si el error es mayor a un umbral, el S^*_{t+1} entra al modelo en lugar de S_t para obtener un comando motriz adicional de afinación a fin de alcanzar la posición deseada de manera precisa.

Se probó el sistema en 220 posturas aleatorias de la cámara. La Fig. 4.15 muestra las 220 posiciones iniciales del centro de masa del estímulo (puntos azules).

La imagen capturada por la cámara en cada postura es alimentada al control sacádico adquirido para producir el movimiento sacádico requerido para centrar el estímulo en la escena visual. Las posiciones del estímulo después de ejecutar el movimiento sacádico de aproximación se presentan en la Fig. 4.15 (puntos rojos), en donde se puede observar la concentración de posiciones del estímulo hacia el centro de la imagen lo cual es prueba del funcionamiento del sistema.

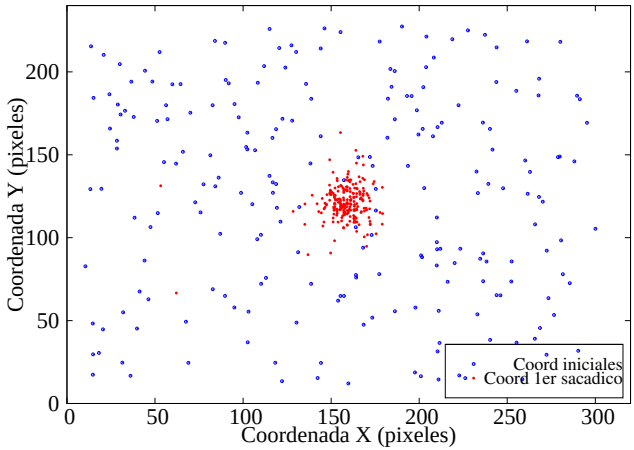

Figura 4.15: *Primer movimiento sacádico de aproximación, posiciones iniciales (azul) y posiciones finales (rojo) en píxeles del estímulo en la imagen.*

El error promedio del primer movimiento sacádico fue de 11.75 píxeles que representa 0,47^o en movimiento de la cámara. Aun cuando este error es pequeño -menos de medio grado- podemos atribuirlo a la fovealización pues cuando el estímulo esta ubicado inicialmente en la periferia de la imagen hay menos información para determinar su posición exacta. Si ejecutamos un segundo movimiento sacádico de afinación sobre la posición del estímulo después de ejecutar el primer movimiento, se disminuye aun mas el error como se muestra en la Fig. 4.16

Podemos ver que la concentración del estímulo al centro de la imagen ha aumentado y que el error ha disminuido a un promedio de 4.3 píxeles, el cual representa sólo 0,16^o de movimiento de la cámara.

4.5. Control sacádico para un Robot humanoide NAO

Se realizó una exploración del funcionamiento de SOIMA sobre una tarea de movimientos sacádicos utilizando el robot humanoide NAO.

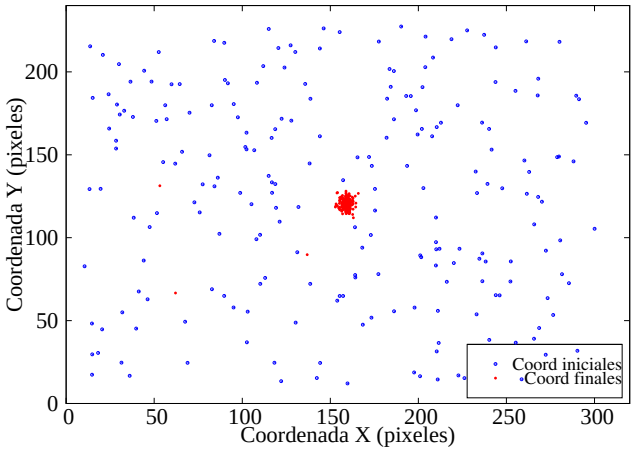

Figura 4.16: *Segundo movimiento sacádico de afinación, posiciones iniciales (azul) y posiciones finales (rojo) en píxeles del estímulo en la imagen*

El esquema propuesto del sistema es similar al utilizado en la sección 4.4 (Fig. 4.4).

La diferencia principal consiste en que el tipo de movimientos que se van a modelar no son propiamente movimientos sacádicos, sino, movimientos de la cabeza del robot humanoide. Esto quiere decir que, en este caso de estudio, el centro del sistema coordenado esta en los ejes de movimiento y que este no coincide con el centro de proyección de la cámara, es decir, que el centro de proyección de la cámara rota de manera excéntrica.

Lo mencionado representa una diferencia considerable en la geometría del sistema con relación al experimento anterior. Si se utilizará una aproximación matemática para resolver esta tarea, entonces se requeriría replantear las ecuaciones que rigen al sistema al tener que incluir parámetros de rotación excéntrica. En nuestro caso, las diferencias del sistema planteadas son del tipo estructural en la organización de las unidades SOM, sin embargo estas tienen el fin de demostrar otras características interesantes de la arquitectura, si dejáramos al sistema como fue planteado para la cámara, no habría motivos para que no se desempeñará correctamente, claro después de haber pasado por el proceso de entrenamiento. Esto último ayuda a complementar la idea de la

versatilidad del sistema para adaptarse al agente.

Plataforma y entorno experimental

Como plataforma de experimentación se utilizó un robot humanoide NAO v5 programable y autónomo desarrollado por Aldebaran Robotics (Fig. 4.17), este robot cuentan con 21 grados de libertad, 2 cámaras en la cabeza, un S.O. basado en LINUX y un SDK multiplataforma para lenguaje C++ y Phyton

Figura 4.17: *Robots Humanoides NAO v5 en laboratorio de robótica cognitiva del Centro de Investigación en Ciencias (CInC).*

Adicionalmente este robot cuenta con los módulos para el simulador Webots de CyberBotics, este simulador provee el motor de simulación física para construir entornos y probar comportamientos en agentes artificiales.

Decidimos utilizar el simulador para probar el sistema de movimientos sacádicos, y construir un entorno experimental consistente en una arena con el robot NAO en el centro, el cual se encuentra orientado hacia una pared situada a 40 cm de distancia sobre la que se ha colocado un solo estímulo visual simple, como se puede apreciar en la Fig. 4.18.

Se usaron los grados de libertad asociados al movimiento de la cabeza: *pitch* que se refiere al movimiento de rotación sobre el eje vertical y *yaw* correspondiente a la rotación sobre el eje horizontal. También se utilizó la cámara superior del agente con una resolución de imagen de 640×480 píxeles.

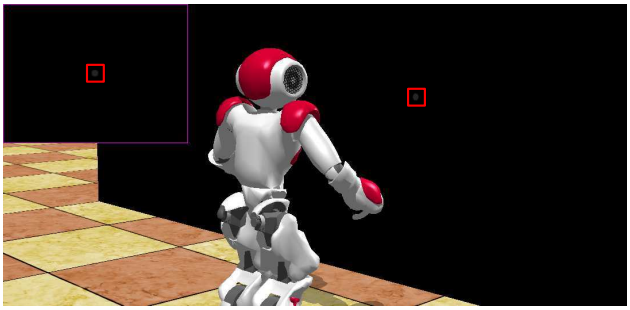

Figura 4.18: *Entorno experimental del control sacádico en el simulador Webots, la imagen capturada por la cámara superior del agente se muestra en el recuadro superior izquierdo.*

4.5.1. Entrenamiento de la red SOIMA

La estructura SOIMA utilizada se muestra en la Fig. 4.19. En este experimento se probó la codificación del estado sensorial al tiempo actual S_t y al tiempo siguiente S_{t+1} en un solo mapa S, debido a que ambos provienen del mismo espacio modal. Para el mapa S se creo un SOM de 30×30 neuronas, el mapa M fue de 40×40 neuronas y el mapa MMR se construyó usando un SOM de 30×30×30 neuronas.

Para construir los patrones de entrenamiento se utilizaron procedimientos similares a los descritos en la sección 4.4.3. Estos procedimientos incluyen el preprocesamiento sensorial, la construcción del comando motriz y el entrenamiento de los SOM.

Para construir los estímulos sensoriales S tanto al tiempo actual como al tiempo siguiente, se requiere de dos etapas de preprocesamiento. En la primer etapa se construye una imagen fovealizada a partir de la imagen original de 640×480 píxeles capturada por la cámara.

Para fovealizar las imágenes aplicamos el mapeo foveal radial con alta resolución al centro de la imagen y baja resolución hacia la periferia usando las ecuaciones y parámetros de la sección 4.4.3. El algoritmo de fovealización entrega una imagen de 320×240.

La segunda etapa de preprocesamiento tiene la función de ayudar a destacar el estímulo relevante en la imagen capturada por la cámara. Se utilizó un función umbral binaria y un suavizado gaussiano. En esta etapa la imagen se

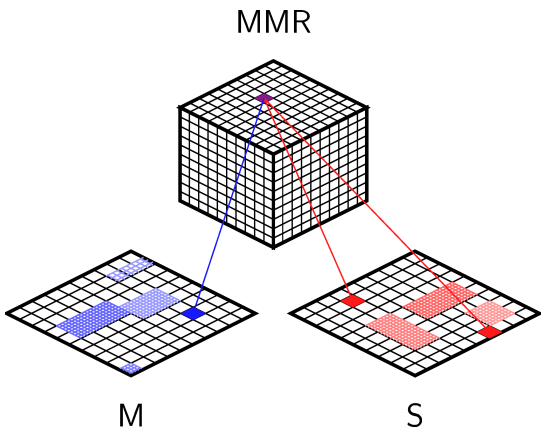

Figura 4.19: *Estructura SOIMA para el control sacadico sobre el robot NAO. Se muestran dos mapas modales, el mapa que codifica el comando motriz* M *y el mapa que codifica el estado sensorial* S*. El mapa superior integra las modalidades codificando el esquema sensorimotriz en una representación multimodal (*MMR*).*

redujo a una imagen de 40×30 píxeles, mediante una pirámide gaussiana multi-resolución (Szeliski, 2010), a una imagen de 40×30 píxeles con la intención de reducir la dimensionalidad espacial. En la Fig. 4.20 podemos ver el prepocesamiento de la entrada sensorial S.

En cuanto a la construcción del comando motriz se utilizó el mismo proceso de fovealización descrito en 4.4.3. Los rangos de movimiento se delimitaron a los valores de $Yaw = [-0{,}38^o, 0{,}38^o]$ y $Pitch = [-0{,}33^o, 0{,}33^o]$ en radianes.

De la misma manera que para el experimento con la cámara Canon, se construyo una imagen de resolución motriz (I_{RM}) en base a 5000 posiciones aleatorias de la cabeza del robot. Dicha imagen se presenta en la Fig. 4.21. Como se puede ver la más alta densidad de aparición del estímulo visual esta localizada en la región central de la imagen.

Los mapas de la estructura SOIMA se entrenaron individualmente utilizando 5000 patrones aleatorios de manera similar que en la sección 4.4.3.

La métrica utilizada para verificar el correcto entrenamiento de los SOM corresponde a la distorsión de la cuantización vectorial (ver sección 3.2.2) que se calcula utilizando la ecuación 4.7.

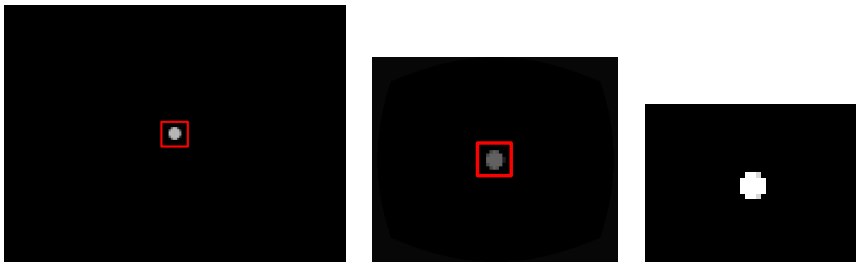

(a) (b) (c)

Figura 4.20: *Preprocesamiento de la imagen de entrada, (a) Imagen original 640x480, (b) Imagen fovealizada 320x240, (c) Imagen destacando el estímulo relevante 40x30.*

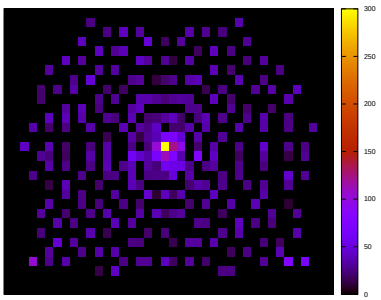

Figura 4.21: *Distribución del estímulo visual sobre 5000 diferentes posiciones de la cabeza del robot con resolución motriz fovealizada.*

$$\xi = \frac{1}{p}\sum_{i=1}^{n}\sum_{x_j \in C_i} \|x_j - \mathrm{w}_i\|^2 \tag{4.7}$$

donde $\{\mathrm{w}_i\}$ es el conjunto vectores de pesos para las n neuronas de un SOM, $\{x_j\}$ es el conjunto finito de p patrones disponibles y C_i esta definido como el grupo de patrones tal que $C_i = \{x|\Phi(x) = \mathrm{w}_i\}$, en donde $\Phi(x)$ es la función que mapea el conjunto de patrones a los vectores de pesos.

En la Fig. 4.22 se muestra la distorsión de cada uno de los SOM del sistema

durante el entrenamiento. En ella podemos observar la disminución escalonada de la distorsión de acuerdo a la reducción del tamaño de vecindad, la cual llega a un valor muy cercano a cero para el tamaño de vecindad uno. El tamaño de vecindad uno corresponde a la modificación solamente de la neurona ganadora. Esta curva indica que el SOM ha alcanzado una buena cobertura del espacio de entrada.

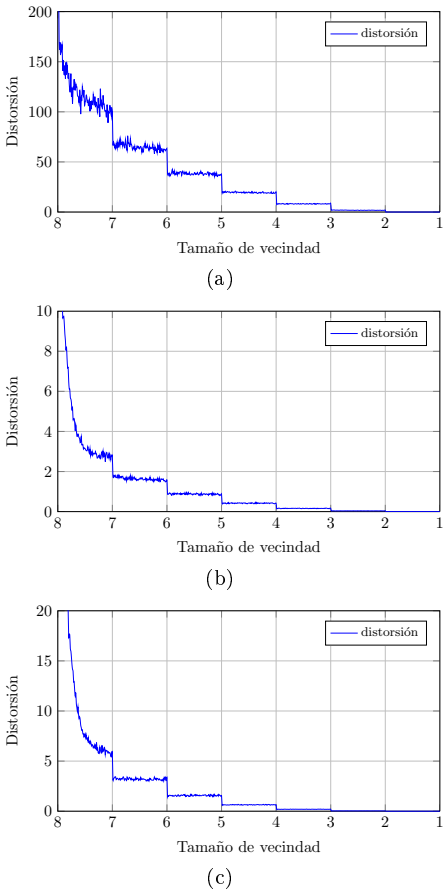

Figura 4.22: *Distorsión durante el entrenamiento de los mapas; (a) distorsión del mapa* S*, (b) distorsión del mapa* M*, (c) distorsión del mapa* MMR*.*

Aprendizaje en linea

Se utilizó el mecanismo de aprendizaje en linea sobre la modulación hebbiana de las conexiones dinámicas. Inicialmente no hay ninguna asociación entre los mapas, es decir todas las conexiones tienen el valor de 0, por lo cual el sistema no puede sugerir ningún comando motriz que permita centrar el estímulo presente en S_t usando el modelo inverso. Esto significa que cuando no se puede obtener un comando motriz se activa el mecanismo de balbuceo motriz que genera un comando M_t aleatorio. Al ejecutar este comando se produce el cambio en el estado sensorial reportado en la imagen S_{t+1}. Esta información se integra en el sistema usando el aprendizaje en linea.

El aprendizaje incrementa gradualmente el conocimiento sensorimotriz de los movimientos sacádicos, lo cual disminuye el porcentaje de uso del balbuceo motriz y aumenta el uso de SOIMA. Este comportamiento se puede apreciar en la Fig. 4.23(a).

El aprendizaje en linea también reduce la media del error al centrar el estímulo visual (Fig. 4.23(b)). En dicha figura podemos apreciar que la media esta afectada por los valores de error discordantes, en este sentido la mediana representa mejor la disminución del error. El rango intercuartil, representada por la barra azul, nos permite observar que la mayor cantidad de errores disminuyen con el entrenamiento y que el primer cuartil se encuentra muy cercano a 0 píxeles de error. Cabe mencionar que el error es considerado como la distancia (en píxeles) entre el píxel central de la imagen y el centro de masa del estímulo presente en la imagen S_{t+1} después de ejecutar el movimiento.

De igual manera que el experimento de control sacádico con la cámara, en este experimento se consideraron los tres casos donde se da el aprendizaje en linea.

En la Fig. 4.24 podemos ver las trayectorias del estímulo durante la ejecución de los comandos motrices en dos situaciones iniciales iguales. La Fig. 4.24(a) muestra la trayectoria del estímulo antes del aprendizaje en linea y la Fig. 4.24(b) después de realizar el aprendizaje. Como se puede apreciar al realizar el aprendizaje se integran los comandos motrices para alcanzar con mayor eficiencia el centrado del estímulo en la imagen.

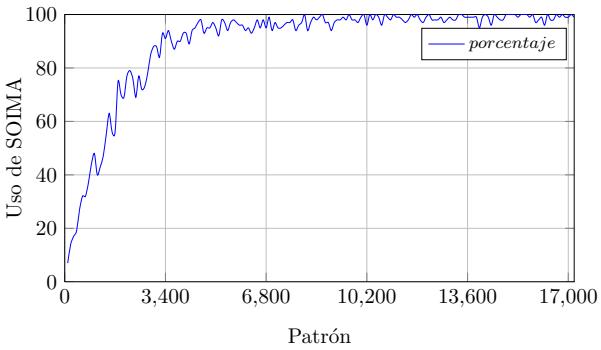

(a)

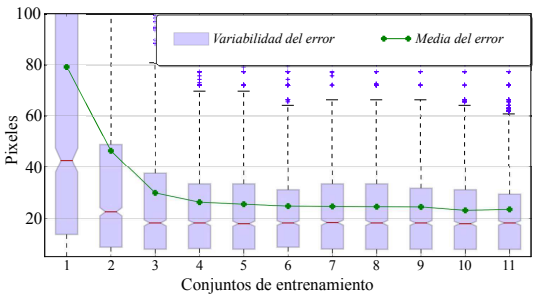

(b)

Figura 4.23: *(a) Porcentaje del uso de SOIMA; (b) Error en píxeles del estímulo al centro de la imagen; en ambas gráficas cada punto respresenta el promedio de 100 patrones.*

4.5.2. Experimentos y resultados

Desempeño de la predicción

El ejemplo típico de la secuencia de predicción se muestra en la Fig. 4.25. En este ejemplo se realizan 2 pasos de predicción:

- Predicción de aproximación: La imagen actual de la cámara es alimentada en el sistema y procesada de acuerdo al sistema de preprocesamiento de la entrada sensorial para formar S_t. La imagen deseada S_{t+1} también

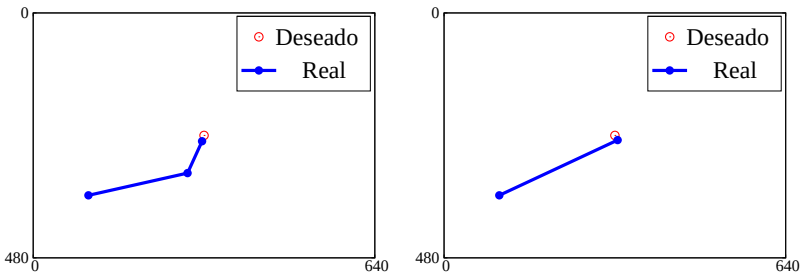

Figura 4.24: *Trayectorias del estímulo durante la ejecución de los movimientos sacádicos antes y después del aprendizaje en linea; (a) trayectoria ejecutada antes del aprendizaje en-linea; (b) trayectoria ejecutada después de realizar el aprendizaje en-linea.*

es alimentada, con el estímulo relevante en el área central. Estas entradas se propagan a través del modelo inverso y generan una sugerencia para el comando motriz M_t. Este es aplicado conjuntamente con S_t al modelo directo para generar una predicción S^*_{t+1}. Finalmente esta salida es comparada con S_{t+1}, la situación deseada, para calcular el error.

- Predicción de afinación: Si el error es mayor que un valor umbral dado como un parámetro experimental, entonces S^*_{t+1} es realimentado al sistema nuevamente a fin de obtener un comando motriz adicional para conseguir la posición objetivo con mayor precisión.

Se realizaron 95 pruebas independientes sobre el desempeño del modelo de control sacádico (Fig. 4.26) (en diferentes posiciones de la cabeza del robot) con el estímulo ubicado en diferentes posiciones sobre la imagen capturada por la cámara (cuadros azules). Se encontró un error promedio de 39.91 píxeles (circulo rojo) para los movimientos sacádicos sugeridos por la arquitectura en el paso 1 (cruces rojas). Este error representa 1,6 % del tamaño de la imagen y 3,4° sobre los movimientos del robot. Para los movimientos sugeridos en el paso 2 (equis verdes), el error promedio fue de 35.72 píxeles (disco verde), el cual significa un error de 1,3 % del tamaño total de la imagen y 3° en referencia a los movimientos del robot.

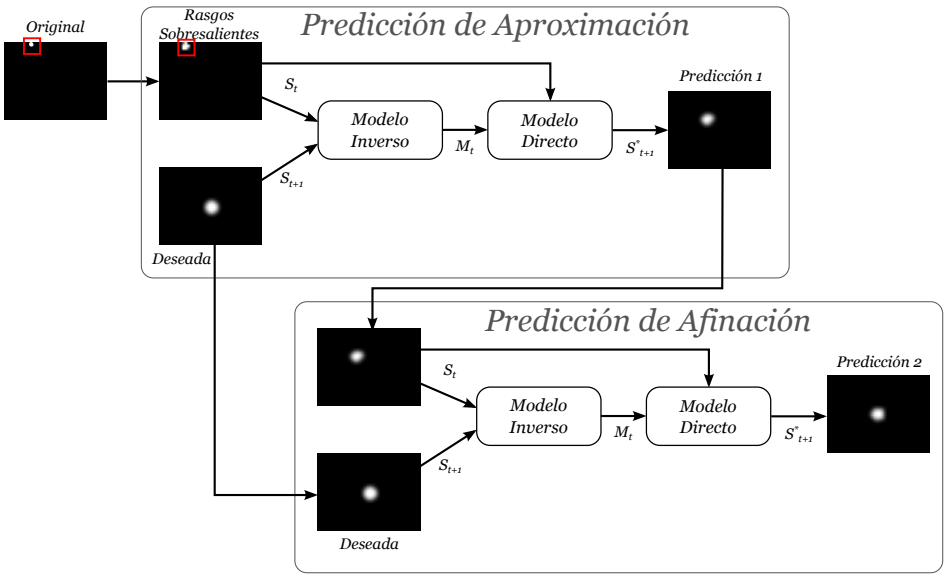

Figura 4.25: *Ejemplo de predicción típica.*

En cierta medida podemos justificar el error promedio de los movimientos sacádicos, debido a la fovealización visual, ya que ésta reduce la información disponible en la periferia de la imagen, lo cual causa imprecisión para determinar la localización del estímulo inicialmente.

Desempeño de la ejecución

Basados en el naturaleza de los movimientos sacádicos del ojo humano (Bahill, et al., 1975), sabemos que de acuerdo a la precisión de los movimientos sacádicos iniciales, se puede o no llevar a cabo un segundo movimiento de corrección.

Derivado de este hecho, después de realizar la secuencia de movimientos sugeridos por el modelo (sacádico inicial o de aproximación), un segundo movimiento de afinación o corrección es ejecutado (Fig. 4.27). Estos dos pasos de ejecución se describen a continuación.

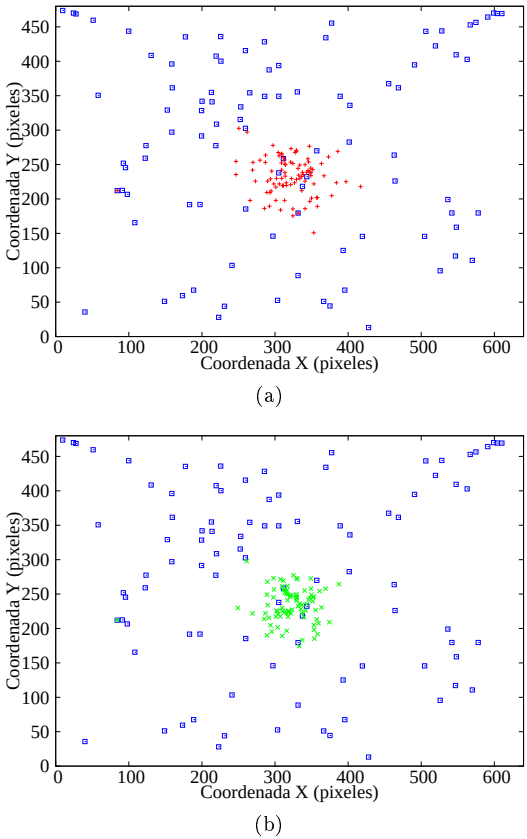

Figura 4.26: *Desempeño de la predicción; (a) desempeño del primer paso de predicción (aproximación), los cuadros azules representan las posiciones iniciales del estímulo en la imagen y las cruces rojas representan la posición del estímulo después del primer paso de predicción; (b) desempeño del segundo paso de predicción (afinación), los cuadros azules representan nuevamente las posiciones iniciales del estímulo mientras que las equis verdes representan la posición del estímulo después del segundo paso de predicción.*

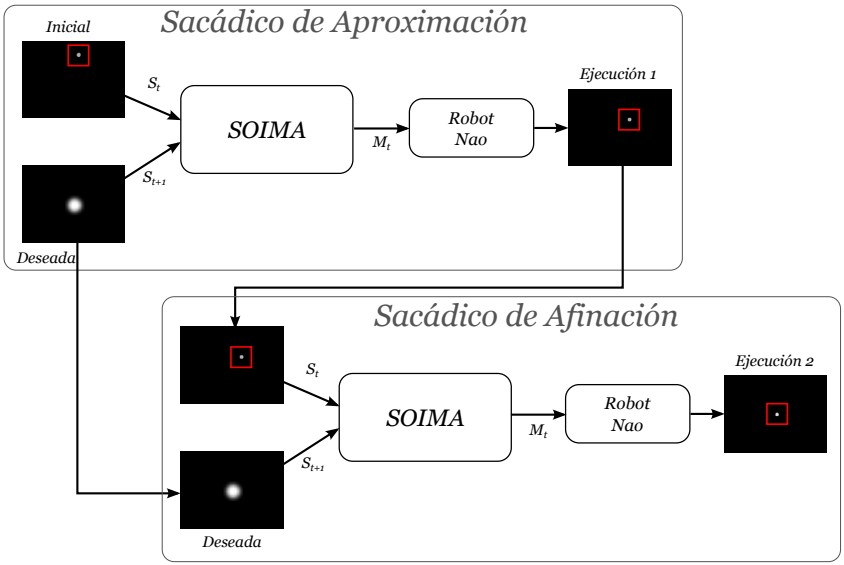

Figura 4.27: *Ejecución de movimientos sacádicos.*

- *Movimiento sacádico de aproximación:* La imagen actual de la cámara es alimentada como S_t, de la misma manera se alimenta la imagen deseada S_{t+1} con el estímulo relevante al centro. Estas entradas pasan a través de SOIMA que genera un comando motriz sugerido M_t que es aplicado al robot NAO. Se evalúa la error entre la imagen producida por la ejecución del comando motriz y la imagen deseada para determinar la pertinencia de ejecutar un segundo movimiento de afinación.

- *Movimiento sacádico de afinación:* Si el error es mayor que un umbral de 10 píxeles (0.1 % de la superficie de la imagen y 0,8° de movimiento del robot, valor determinado de manera empírica), la imagen actual es realimentada nuevamente a SOIMA para obtener un comando motriz adicional de afinación que permite alcanzar la posición deseada con mayor precisión y por tanto disminuir el error.

El sistema se probó sobre 84 patrones y se encontró un error promedio de 36.1 píxeles en relación a la imagen de 640×4800, lo cual corresponde a 3,1°

de error en los movimientos sacádicos de aproximación. Para el movimiento de afinación se obtuvó un error de 19.3 píxeles que corresponde a 1,6° de error (Fig. 4.28).

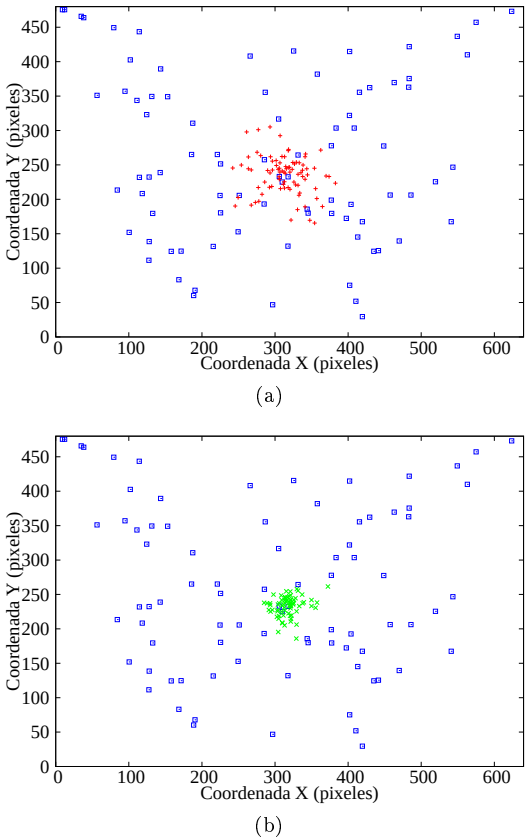

Figura 4.28: *Desempeño de la ejecución; (a) desempeño del movimiento sacádico de aproximación, los cuadros azules presentan las posiciones iniciales del estímulo en la imagen, las cruces rojas son las posiciones del estímulo después del primer movimiento sacádico de aproximación; (b) desempeño del movimiento sacádico de afinación, las equis verdes presentan la posición del estímulo después del movimiento sacádico de afinación.*

Adicionalmente se realizó un experimento de seguimiento del estímulo sobre una trayectoria. En este experimento el estímulo fue desplazado sobre el plano de la pared frente al robot, mientras el robot realiza la tarea de centrarlo haciendo uso del controlador sacádico adquirido. El objetivo es mostrar que aun cuando la referencia espacial del estímulo con respecto al robot cambia y por tanto la perspectiva, el robot es capaz de usar efectivamente el controlador sacádico.

En la Fig. 4.29 se muestra una trayectoria de seguimiento. En donde las flechas rojas muestran la secuencia en la trayectoria del movimiento del estímulo. Los números asociados a cada una de las flechas corresponde al número de movimientos sacádicos realizados para centrar el estímulo en la imagen. Finalmente los números y círculos en azul muestran el error en píxeles de la tarea de centrado sobre cada uno de los puntos en la trayectoria.

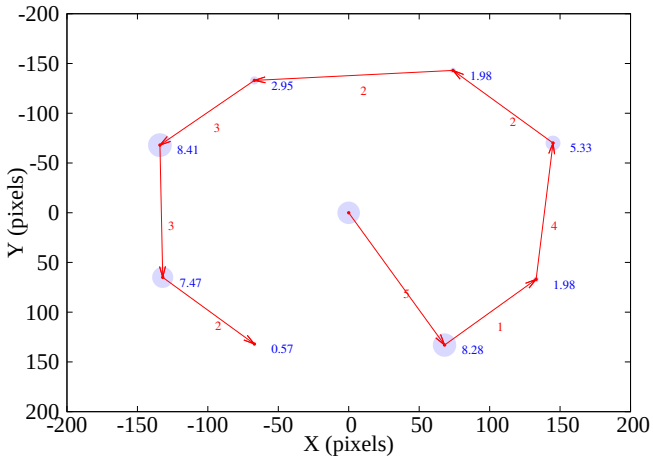

Figura 4.29: *Trayectoria del estímulo sobre el plano de la imagen del robot, las flechas y números en rojo muestran la trayectoria y el número de movimientos sacádicos en cada una de las tareas de centrado, los círculos y números azules muestran el error en píxeles después de realizar el centrado del estímulo.*

Capítulo 5

Casos de estudio

A fin de probar la factibilidad y desempeño de la arquitectura, se implementaron varios casos de estudio. El primer caso de estudio implementado, una estrategia de cordinación ojo-mano, permitió mostrar como SOIMA puede ser escalado con el fin de modelar tareas cognitivas más complejas. En el segundo experimento se exploró la organización de la representación multimodal y su relación con la información modal a través de una caracterización de trayectorias. El tercer caso de estudio presenta una variante de la arquitectura mediante el uso de SOM dinámicos. Esta variante permite simular la recuperación del sistema a una lesión o cambio del agente por medio de un mecanismo básico de plasticidad.

5.1. Coordinación ojo-mano en el robot NAO

En las etapas iniciales del desarrollo, los infantes aprenden de manera progresiva a fijar su atención hacia los eventos relevantes de su entorno, tales como los objetos en movimiento, objetos contrastantes, su propio cuerpo, entre otros (Law, et al., 2011). Se ha mostrado que hay un acoplamiento temprano entre los sistemas visuales y motrices de los infantes. Coordinar la percepción visual con movimientos del cuerpo es un requisito fundamental para el desarrollo de habilidades motoras y cognitivas complejas.

La coordinación visuo-motriz subyace del proceso de mapear la visión espacial a los patrones de activación muscular. Dicho mapeo es aprendido mediante la interacción física del agente con su entorno. En particular la coordinación ojo-mano (Hand-Eye Coordination HEC) se refiere al uso coordinado de los ojos y una o ambas manos para llevar a cabo una tarea.

Para probar las capacidades de SIOMA se presenta una implementación del problema de HEC utilizando el robot humanoide NAO (Fig. 5.1). Este esquema integra la postura del brazo del agente, la postura de su cabeza y la información visual del agente. Esta integración se codifica como una representación multimodal.

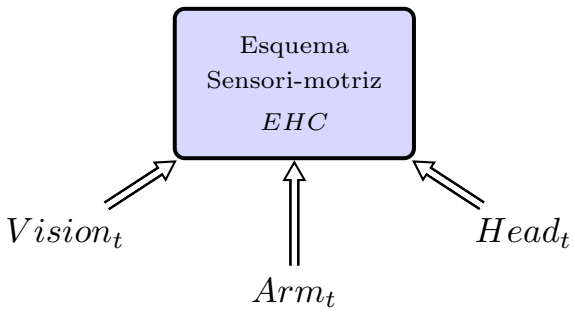

Figura 5.1: *Esquema sensorimotriz para la EHC, en el cual se realiza la integración del conocimiento de las correspondencias entre los movimientos del brazo, de la cabeza y la entrada visual.*

Para modelar este esquema sensorimotriz se propone la estructura SOIMA que se puede apreciar en la Fig. 5.2 en donde se observa la integración de la EHC al control sacádico. En cuanto al sistema de coordinación el mapa V corresponde a la entrada visual, el mapa $Head$ corresponde a la posición de las articulaciones de la cabeza, el mapa Arm representa las uniones del brazo izquierdo del robot y finalmente el MMR_{eh} es el mapa en donde se hace la representación multimodal del esquema sensorimotriz. Por otra parte el control sacádico utilizó los SOM's descritos en el anterior caso de estudio.

En este experimento el control sacádico sirvió de apoyo para realizar el entrenamiento y la prueba de la EHC. La función que realizó el controlador sacádico consistió principalmente en centrar el marcador en la imagen una vez que es detectado sobre la escena. Al mismo tiempo permitió el seguimiento visual del marcador. Debido a que tanto en la EHC como en el control sacádico la entrada visual V tiene la misma naturaleza, se utilizó el mismo mapa.

Esta estructura permite explorar las capacidades de la arquitectura SOIMA al acoplar dos sistemas distintos que utilizan unidades SOM de manera compartida.

Cabe hacer mención que el sistema propuesto utiliza la información propioceptiva del agente como modalidad motriz, en específico la postura de la cabeza y del brazo del robot.

En función de la tarea es que se determina si un mapa en particular actúa como entrada o salida ya que, como se ha mencionado anteriormente (sección

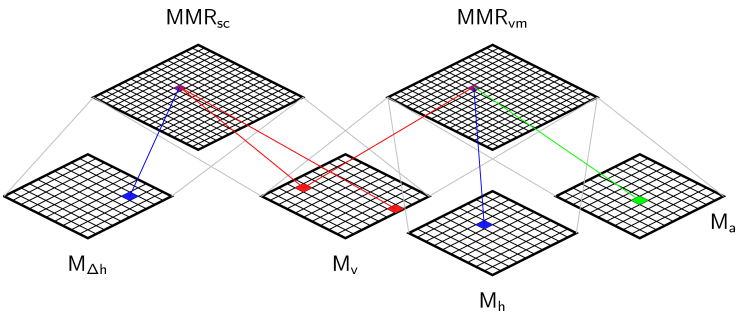

Figura 5.2: *Estructura SOIMA para la EHC. Se muestran 4 mapas modales, 2 de ellos correspondientes exclusivamente a la EHC que son Head, Arm; uno exclusivo del control sacádico $\Delta Head$, mientras que V es un mapa compartido en los dos esquemas. Los mapas superiores integran las modalidades codificando el esquema sensorimotriz de cada comportamiento en una representación multimodal (MMR_{eh} y MMR_{sc}).*

4.3), SOIMA permite un flujo bidireccional de información.

Por ejemplo, una vez adquirida la coordinación visuo-motriz, el sistema puede proveer la postura necesaria de la cabeza para ubicar su mano en la entrada visual. La descripción de los pasos que se seguirían en este caso se mencionan a continuación:

- Se presenta la información sensorial propioceptiva del brazo, lo cual activa alguna neurona del mapa $\mathsf{M_a}$ que funciona como entrada a SOIMA.
- La activación del mapa $\mathsf{M_a}$ se propaga hacia el mapa superior $\mathsf{MMR_{vm}}$.
- El mapa superior $\mathsf{MMR_{vm}}$ propaga su activación al mapa $\mathsf{M_h}$ que actúa como salida y produce la situación sensorial propioceptiva de la cabeza.
- Finalmente la información propioceptiva de la cabeza se tomo como comando motriz para posicionar la cabeza del agente.

De manera similar el sistema podrá proveer la postura necesaria del brazo para que aparezca la mano en la entrada visual, los pasos se describen a continuación:

- Se presenta la información sensorial propioceptiva de la cabeza, esta activa alguna neurona del mapa M_h que en esta ocasión se desempeña como entrada a SOIMA.
- La activación del mapa M_h se propaga hacia el mapa superior MMR_{vm}.
- El mapa superior MMR_{vm} propaga su activación al mapa M_a que actúa como salida y produce la situación sensorial propioceptiva del brazo.
- Finalmente la información propioceptiva del brazo se toma como comando motriz para posicionar el brazo del agente.

En cuanto a la estructura del control sacádico se utilizó el sistema propuesto en la sección 4.4.

5.1.1. Plataforma y entorno experimental

Como plataforma se utilizó un robot NAO y el simulador Webots para probar el sistema de coordinación visuo-motriz. Se construyó un entorno experimental consistente en una arena con el robot NAO en el centro, el cual tiene un marcador fiduciario anclado en la muñeca del brazo izquierdo, y una pequeña caja con la imagen del marcador. Esta última tiene el propósito de probar el sistema cuando ya se encuentre entrenado. Este entorno se puede apreciar en la Fig. 5.3.

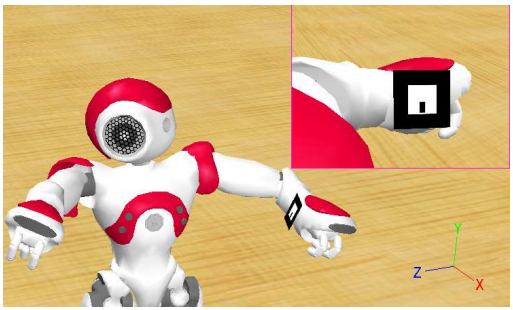

Figura 5.3: *Entorno experimental para la coordinación visuo-motriz en el simulador Webots.*

Se utilizó la cámara situada en la parte inferior de la cabeza del robot con una resolución de 640 × 480 píxeles, 2 grados de libertad de la cabeza del agente (*yaw, pitch*) y 4 grados de libertad del brazo (*shoulder pitch, shoulder roll, elbow yaw, elbow roll*).

5.1.2. Entrenamiento

Para llevar a cabo el entrenamiento de los SOM's modales fue necesario construir un conjunto de patrones de entrenamiento. Dichos patrones estuvieron conformados por 3 elementos:

- Información Visual: las coordenadas del marcador en el plano de la imagen. Esta información codificada en el mapa $\mathsf{M_v}$.
- Información propioceptiva de la cabeza: los ángulos de los dos grados de libertad (*yaw*, *pitch*). Esta información codificada en el mapa $\mathsf{M_h}$.
- Información propioceptiva del brazo: las posiciones angulares de las 4 articulaciones del brazo (*LShoulderPitch*, *LShoulderRoll*, *LElbowYaw*, *LElbowRoll*).

Para obtener la entrada para el mapa $\mathsf{M_v}$ se utilizó la librería ARToolkit (www.hitl.washington.edu/artoolkit) para calcular la posición del marcador en el sistema coordenado de la imagen.

A fin de obtener la entrada para el mapa $\mathsf{M_h}$ se comenzó por determinar los rangos de movimiento que facilitarán la aparición del marcador en la escena visual. Esto llevó a restringir los movimientos a solo la mitad del rango en Yaw a fin de sesgar la orientación de la cabeza hacia la mano izquierda. Los rangos utilizados fueron $Yaw = [0^o, 70^o]$ y $Pitch = [-19^o, 19^o]$. Estos valores se normalizaron a un rango de [0,1].

Para la entrada del mapa $\mathsf{M_a}$ se determinaron los siguientes rangos $LShoulderPitch = [-40^o, 70^o]$, $LShoulderRoll = [-18^o, 76^o]$, $LElbowYaw = [-100^o, 20^o]$ y $LElbowRoll = [-88{,}5^o, -10^o]$; y se normalizaron a valores entre [0,1].

Finalmente para el sistema de control sacádico del robot, se utilizaron patrones construidos mediante el procedimiento descrito en la sección 4.5.1. Sin embargo se adecuaron los rangos de movimiento de la cabeza.

Por otra parte para el sistema de control sacádico del robot, se utilizaron los mismos patrones para $V_{t,t+1}$, en cuanto para $\Delta Head$ se utilizó el cambio motriz

en dos posiciones distintas del marcador V_t y V_{t+1} distribuidas uniformemente, con los mismos rangos de $Head$.

Entrenamiento SOM

Debido a que la entrada sensorial visual tanto para el control sacádico como para la coordinacion visuo-motriz tiene la misma naturaleza sólo es necesario un mapa $\mathsf{M_v}$ para su codificación.

Se utilizó un mapa de 40×40 neuronas para $\mathsf{M_v}$, el mapa $\mathsf{M_h}$ fue de 40×40 unidades, para el mapa $\mathsf{M_a}$ se usaron 60×60 neuronas, el $\Delta Head$ de 50x50, el MMR_{vm} (visuo-motriz) de 70x70 y el MMR_{sc} (sacádico) de 70x70. Estos mapas se entrenaron individualmente utilizando la información de 6453 patrones aleatorios.

La métrica utilizada para verificar el correcto entrenamiento de los SOM corresponde a la distorsión de la cuantización vectorial (ver sección 3.2.2) que se calcula utilizando la ecuación 4.7.

En la Fig. 5.4 podemos ver la distorsión de cada uno de los SOM del sistema, donde se muestra la disminución escalonada de la distorsión de acuerdo a la reducción del tamaño de vecindad, la cual llega a un valor muy cercano a 0 para el tamaño de vecindad 1 (en donde la modificación de los pesos sólo se realiza sobre la sola neurona ganadora). Las curvas descritas por la distorsión de cada mapa indican que se ha alcanzado la cobertura de la distribución de los patrones hacia el final del entrenamiento.

En la Fig. 5.5 se puede apreciar la cobertura de las unidades de los SOM sobre las distribuciones de los patrones de entrenamiento

El entrenamiento de las asociaciones hebbianas de la HEC se realizó mediante balbuceo motriz orientado al objetivo (Baranes y Oudeyer, 2013) sobre los grados de libertad involucrados en el sistema. El procedimiento general del entrenamiento consistió de la ejecución de movimientos aleatorios del brazo del robot, mientras el sistema provee la postura de la cabeza que permita percibir la mano en la entrada visual. En caso de que el sistema no este lo suficientemente entrenado para proveer dicha postura entonces se genera una postura aleatoria para la cabeza. Cuando la mano es detectada en la entrada visual, se asocian las conexiones entre las neuronas correspondientes a las posturas de la cabeza, del brazo así como de la entrada visual.

Durante el entrenamiento, el control sacádico fue utilizado para aumentar la variedad y precisión de los patrones usados durante la asociación hebbiana. Esto es, cuando la mano era detectada y no se encontraba en la parte central

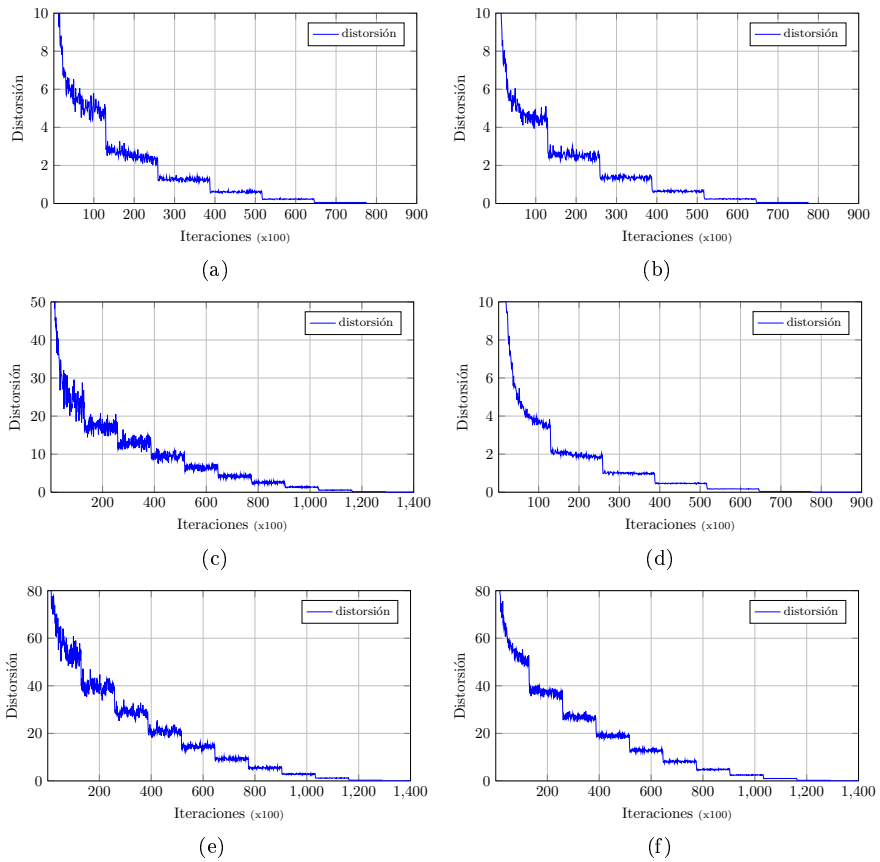

Figura 5.4: *Distorsión durante el entrenamiento de los SOM's; (a)* $\mathsf{M}_{\Delta\mathsf{h}}$*, (a)* M_{v}*, (b)* M_{h}*, (d)* M_{a}*, (e)* $\mathsf{MMR}_{\mathsf{vm}}$ *y (f)* $\mathsf{MMR}_{\mathsf{sc}}$*.*

de la entrada visual entonces se activaba el control sacádico para proveer los comandos motrices necesarios para centrar la mano en la escena visual.

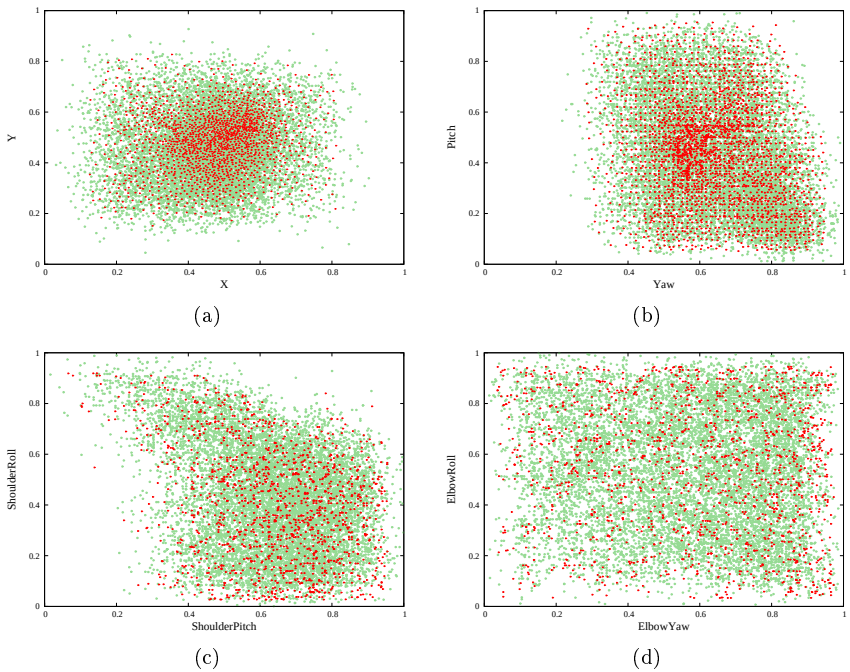

Figura 5.5: *Cobertura de los SOM sobre los patrones de entrenamiento; los puntos azules muestran la distribución sobre 10k patrones de entrenamiento, mientras los puntos rojos muestran las neuronas de cada SOM. En (a) se muestra la cobertura del mapa* $\mathsf{M_v}$ *donde los puntos representan la ubicación del marcador en el plano de la imagen, (b) corresponde al mapa* $\mathsf{M_h}$ *y finalmente (c) y (d) muestran la cobertura del SOM* $\mathsf{M_a}$.

5.1.3. Resultados

Mediante el balbuceo motriz se tomaron 10292 patrones. En la Fig. 5.6 se puede ver el incremento en el porcentaje de uso del sistema durante el entrenamiento. El aprendizaje del sistema gradualmente incrementa el conocimiento de la *HEC* y reduce el uso de posturas aleatorias.

Por otra parte, el aprendizaje del sistema también aumento el número de ocasiones que es posible ubicar la mano en el campo de visón del agente. Se

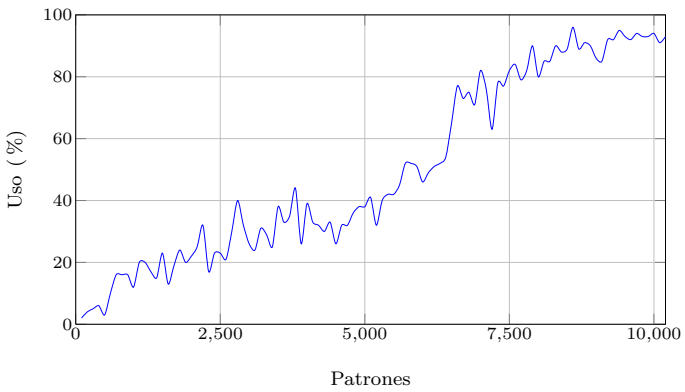

Figura 5.6: *Uso de SOIMA durante el entrenamiento* Goal Babbling.

calculo el porcentaje que es detectada la mano en la escena visual cada 100 patrones. En la Fig. 5.7 se observa el incremento en el porcentaje. El hecho de que el porcentaje nunca llegue al 100 % se debe, por una parte al igual que en la gráfica anterior, a aquellas posturas del brazo que no son posibles de observar en el campo de visión de la cámara. Por otra parte tiene que ver con el hecho de que SOIMA al buscar entre las relaciones sensorimotrices sugiere una postura aproximada de acuerdo al conocimiento adquirido, lo cual puede llevar a imprecisión en la ubicación del marcador. Sin embargo la tendencia positiva de la gráfica es un indicador de la adquisición de la coordinación visuo-motriz.

Con el fin de evaluar el sistema completo se realizó una prueba donde el robot realizó movimientos aleatorios de su brazo los cuales se alimentaron al sistema SOIMA; el sistema a su vez proporcionó los comandos motrices a la cabeza del agente para ubicar y seguir la mano dentro de la escena visual.

En la Fig. 5.8 se muestran las 12032 posiciones de la mano del agente en el espacio 3D durante el movimiento aleatorio del brazo. Los puntos gris oscuro representan aquellas posiciones en las que, después de realizar el movimiento correspondiente de la cabeza, se detecto el marcador en la escena visual. Los puntos gris claro, por su parte, representan las posiciones en las cuales no se detecto el marcador.

Podemos apreciar que las posiciones de la mano en las cuales la HEC falla son aquellas en las que la mano se encuentra en la periferia del espacio alcanzable. Debido a las restricciones físicas de movimiento del cuello no pudo

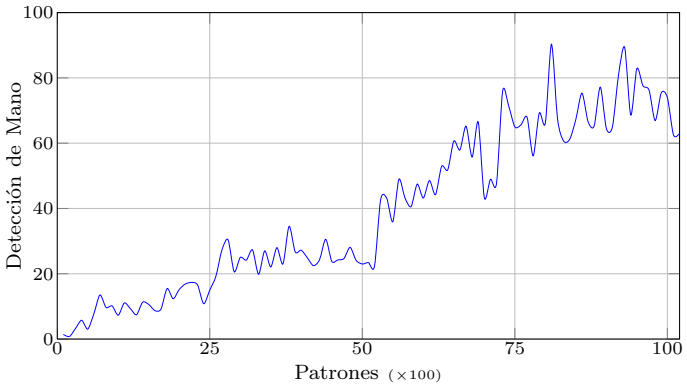

Figura 5.7: *Incremento en el porcentaje que el marcador es detectado durante el entrenamiento; cada punto se calculo sobre 100 patrones.*

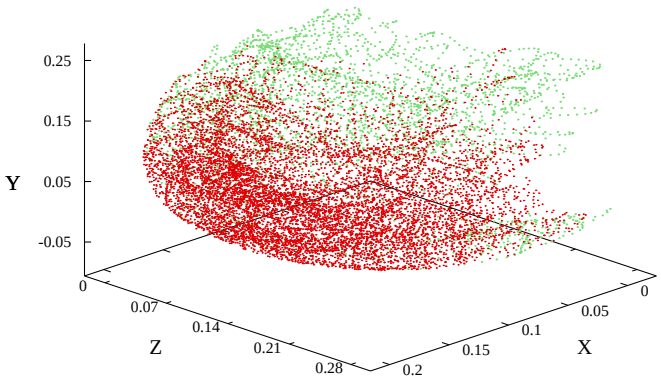

Figura 5.8: *Espacio de detección de la mano por el esquema de coordinación ojo-mano; Se muestran 12032 posiciones aleatorias de la mano, los puntos gris oscuro representan las posiciones donde la HEC es exitosa y mientras los puntos gris claro indican aquellas posiciones donde la HEC falla.*

realizarse un movimiento de la cabeza que ubicará la mano en la escena visual. Por este motivo dichas posiciones de la mano no fueron asociadas con una postura de la cabeza del agente.

El video de este seguimiento visual de la mano se encuentra disponible en la siguiente dirección: https://youtu.be/agrkeUxiQZA.

Finalmente, se llevó a cabo una prueba de señalización, en la cual el agente tiene que detectar el marcador, centrarlo y señalarlo con la mano. La secuencia de ejecución contemplo los siguientes pasos:

- Se colocó una pequeña caja con el marcador en una posición aleatoria de la arena, en un área que pueda ser visible por el robot.
- El agente realizó una exploración aleatoria del espacio visual.
- Cuando es detectado el marcador en la entrada visual, el sistema de control sacádico realizó los movimientos necesarios para centrarlo en la imagen.
- Por último el sistema utilizó el esquema sensorimotriz de coordinación ojo-mano para posicionar la mano frente al marcador.

En la Fig. 5.9 se presenta las fases de la señalización en un ejemplo típico.

El video de la ejecución de esta prueba se puede encontrar en el enlace siguiente: https://www.youtube.com/watch?v=4GagCmoI9x4.

Además se probó este comportamiento iterativamente, repitiendo la señalización continuamente. El video de esta prueba se puede ver en el siguiente enlace: https://www.youtube.com/watch?v=BrFS7EWz4kc.

Como prueba adicional, se probó el sistema entrenado en el agente real. Se obtuvieron los mismos resultados, lo cual indica que la brecha que existe entre el funcionamiento del simulador y el robot real, se puede superar mediante la generalidad capturada por el sistema. El video de la ejecución típica de la tarea de seguimiento visual de la mano se puede encontrar en: https://youtu.be/7h_luKEre5s. De igual forma los videos de ejecución del agente real para la tarea de señalización y señalización continua se pueden encontrar en los siguientes enlaces: https://www.youtube.com/watch?v=Kikd7uDgV_I, https://www.youtube.com/watch?v=ed7WkMgjybo.

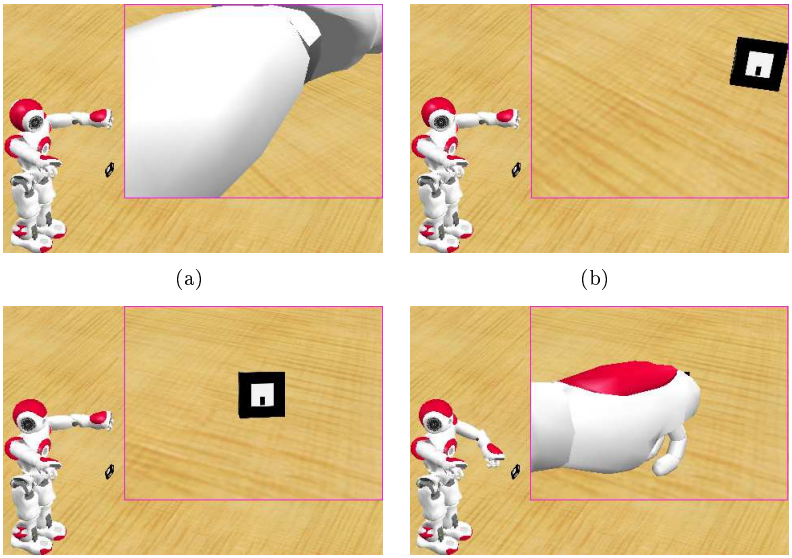

(a) (b) (c) (d)

Figura 5.9: *Fases en el ejemplo típico de prueba para la tarea de señalización; (a) posición inicial aleatoria de la búsqueda, (b) detección del marcador durante la búsqueda, (c) resultado del comportamiento de control sacádico, (d) Brazo apuntado a la dirección del marcador después de aplicar la coordinación visuo-motriz.*

5.2. Caracterización de trayectorias

El primer nivel del ciclo de percepción-acción requiere la habilidad de sentir una extremidad y mover dicha extremidad, denominados propiocepción y control motriz. Ambas señales pasan a través del talamo y se proyectan a la corteza motriz, la cual ha sido demostrado esta organizada en una representación somatotopica del cuerpo (el homunculo) (Grodd, et al., 2001).

Por su parte Graziano, et al. (2002) investigaron la naturaleza de la información codificada por las neuronas de la corteza motriz en el mono, y demostraron que una estimulación persitente (500ms) de regiones especificas de la corteza evocan posturas especificas de una o mas partes corporales. La estimulación en tales zonas resulta en una trayectoria que lleva al brazo a una

posición específica en el espacio. En este sentido, algunas regiones de la corteza motriz pueden ser vistas como una colección de posturas corporales. La estimulación de esta lleva a una secuencia de comandos motrices que tiene como resultado el adoptar una postura.

En el experimento de caracterización de trayectorias presentado en este apartado, se propone una estructura SOIMA que toma inspiración de la organización somatotopica de las zonas corticales y su estimulación para la recreación de trayectorias. Esta estructura estuvo constituida por dos niveles jerárquicos. El nivel inferior se encuentra constituido por un SOM modal $\mathsf{M_a}$ que mapea la propiocepción de las articulaciones del brazo izquierdo de un agente robótico. Dicha propiocepción codifica una postura del brazo del agente, más aun, se codifica de manera implícita una posición cartesiana del efector final del brazo (mano izquierda) en el espacio de trabajo del robot. El nivel superior, por su parte, contiene un mapa de asociación $\mathsf{MMR_{path}}$ en el que se codifican trayectorias de la mano del agente. Cada neurona de este mapa se conecta a 4 neuronas del mapa $\mathsf{M_a}$. De esta forma cada neurona del mapa superior asocia una secuencia de 4 posiciones del brazo del agente, desde t a $t+3$, correspondientes a una trayectoria de su mano. En la Fig. 5.10 se muestra la estructura SOIMA propuesta y la relación jerárquica establecida entre los mapas $\mathsf{MMR_{path}}$ y $\mathsf{M_a}$.

5.2.1. Plataforma y entorno experimental

Como plataforma de experimentación para este caso de estudio se empleo un robot humanoide NAO v5 (sección 4.5). Se usaron los 4 grados de libertad referentes al movimiento del brazo izquierdo, entre los cuales dos grados corresponden al movimiento del hombro*shoulder pitch* y *shoulder roll* y los otros dos grados de libertad controlan el movimiento del codo *elbow yaw* y *elbow roll*.

Se utilizó el simulador Webots para probar la caracterización de trayectorias, el entorno experimental consistió del robot NAO situado en una arena vacía, similar al entorno para el caso de estudio de la coordinación ojo-mano (sección 5.1.1 Fig. 5.3).

5.2.2. Entrenamiento de SOIMA

Se utilizó un SOM de 20 × 20 neuronas para codificar $\mathsf{M_a}$ y un SOM de 10 × 10 neuronas para el $\mathsf{MMR_{path}}$.

Para entrenar al mapa M_a se realizó un balbuceo motriz sobre el brazo

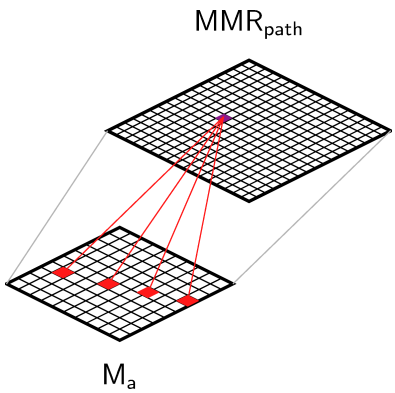

Figura 5.10: *Estructura SOIMA para el experimento de caracterización de trayectorias; Se muestran 2 mapas: el mapa modal* $\mathsf{M_a}$ *que codifica la propiocepción de las articulaciones del brazo izquierdo de un agente robótico, y el mapa de asociación* $\mathsf{MMR_{path}}$ *que organiza un conjunto de 4 posturas (desde* t *a* $t+3$*) del brazo del agente sobre una trayectoria de movimiento.*

izquierdo del agente, mediante lo cual se generaron 1600 posiciones del brazo. Usando cada una de estas posiciones se creo un patrón de entrenamiento de 4 elementos correspondientes a las posiciones angulares de los 4 grados de libertad del brazo (*LShoulderPitch*, *LShoulderRoll*, *LElbowYaw*, *LElbowRoll*).

Con el fin de acotar el aprendizaje, el balbuceo motriz se restringió a una región cuadrada del plano ZY con respecto al origen de coordenadas. Sobre el eje Z el rango de movimiento fue de 3 a 15 cms y sobre el eje Y de 8 a 20 cms. En la Fig. 5.11 podemos ver el origen de coordenadas en el torso del agente, así como el plano imaginario sobre el cual se realizan los movimientos de la mano del agente, dicho plano se estableció a 17 cm del origen de coordenadas y perpendicular al eje X.

Una vez entrenado, el mapa M_a contiene una codificación organizada de las posturas del brazo y actúa como una herramienta para producir los comandos para controlarlo.

Para efectuar el entrenamiento del mapa $\mathsf{MMR_{path}}$ se construyó un conjunto de patrones de 16 elementos cada uno, referidos a los 4 grados de libertad del brazo en 4 instantes (desde t a $t+3$) sobre una trayectoria de la mano izquierda del robot NAO.

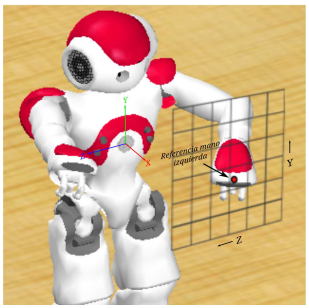

Figura 5.11: *Plano sobre el que se realizan los movimientos del efector final del brazo izquierdo para la tarea de caracterización de trayectorias.*

En total, se utilizaron 400 trayectorias de la mano izquierda del robot NAO cada una de las cuales dio origen a un patrón de entrenamiento. Una trayectoria fue considerada como el movimiento de la mano del agente desde una posición inicial aleatoria hasta una posición final sobre el espacio 3D en el que esta inmerso el robot NAO. El origen del sistema 3D coordenado se situó en el torso del agente. El primero de los 4 puntos equidistantes sobre la trayectoria fue la posición inicial de la mano y el último punto correspondió a la posición final de la mano.

Las 400 trayectorias de la mano se crearon de la siguiente manera:

- Trayectorias verticales: en 100 trayectorias se restringió el movimiento de la mano a sólo desplazamiento sobre el eje Y.
- Trayectorias horizontales: 100 trayectorias con desplazamiento sólo sobre el eje Z.
- Trayectorias diagonales:
  - 100 trayectorias con orientación de 45° sobre el plano ZY.
  - 100 trayectorias con orientación de 135° sobre el plano ZY.

Para verificar el correcto entrenamiento de los mapas se utilizó la distorsión de la cuantización vectorial (sección 3.2.2).

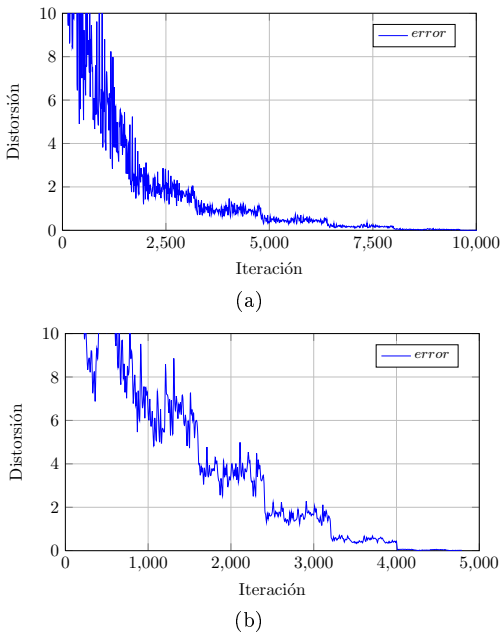

Figura 5.12: *Distorsión durante el entrenamiento de los SOM's; (a)* $\mathsf{MMR}_{\mathsf{path}}$*; (b)* M_{a}.

En la Fig. 5.12 se muestra la distorsión de los dos mapas del sistema, se puede apreciar que la distorsión disminuye hasta un valor muy cercano a 0 lo que indica que se ha alcanzado la cobertura de la distribución de los patrones.

Las conexiones dinámicas entre las neuronas de los mapas se entrenaron utilizando los 400 patrones de diferentes trayectorias recolectados.

5.2.3. Experimentos y Resultados

La arquitectura SOIMA nos permite aplicar estimulación sobre una neurona en un mapa, la activación de dicha neurona se propaga sobre sus conexiones hacia otros mapas.

Se probó la estimulación directa de las neuronas del SOM de integración multimodal $\mathsf{MMR}_{\mathsf{path}}$. Al estimular una neurona del mapa superior esta se propaga hacia el mapa M_{a} activando cuatro neuronas que codifican las posturas

del brazo durante una trayectoria de la mano del agente. De esta manera es posible recrear la secuencia de posturas de la trayectoria correspondiente a cada unidad del $\mathsf{MMR}_{\mathsf{path}}$.

En la Fig. 5.13 se muestra el proceso de recreación de una trayectoria horizontal. En la Fig. 5.13(a) se aprecia la estimulación de la neurona 3 (neurona resaltada en rojo) sobre el mapa $\mathsf{MMR}_{\mathsf{path}}$ entrenado. Por su parte la Fig. 5.13(b) exhibe las 4 neuronas activas en el mapa M_{a} correspondientes a la propagación de la estimulación de la neurona 3 en el $\mathsf{MMR}_{\mathsf{path}}$. Finalmente, en la Fig. 5.13(c) se puede observar la trayectoria horizontal recreada por el agente.

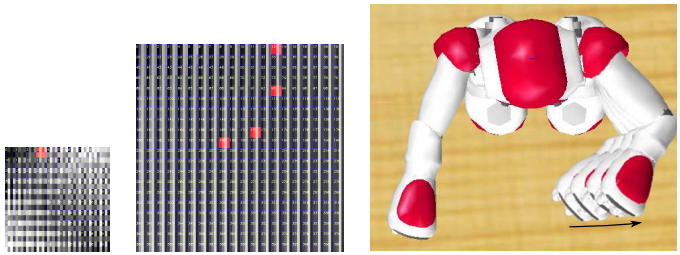

(a) (b) (c)

Figura 5.13: *Recreación de una trayectoria horizontal al estimular una neurona del* $\mathsf{MMR}_{\mathsf{path}}$ *entrenado.*

Por otra parte, en la Fig. 5.14 se aprecia, de forma similar a la figura anterior, el proceso de recreación de una trayectoria vertical. En la Fig. 5.14(a) se presenta la estimulación de la neurona 85 sobre el mapa $\mathsf{MMR}_{\mathsf{path}}$ entrenado. La Fig. 5.14(b) expone las neuronas activas en el mapa M_{a} resultado de la estimulación en el $\mathsf{MMR}_{\mathsf{path}}$. Por último, en la Fig. 5.14(c) se puede observar la trayectoria vertical realizada por el agente.

Aplicando este proceso de recreación, se construyó la Fig. 5.15 en donde se observa la trayectoria recreada al estimular cada neurona que compone el $\mathsf{MMR}_{\mathsf{path}}$. Cada trayectoria es presentada en el plano ZY.En la figura se puede observar la organización que surge en el $\mathsf{MMR}_{\mathsf{path}}$ relacionada al tipo de trayectoria. En la parte izquierda de la figura, se muestra un acercamiento a una neurona a fin de clarificar las dimensiones de las trayectorias y la relación que guardan con respecto al origen de coordenadas. Cabe mencionar que tanto el eje Z, como el Y se encuentran en la escala de centímetros.

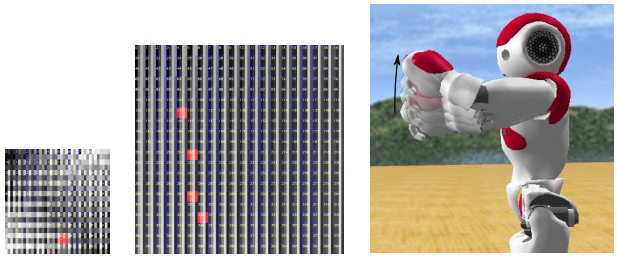

(a) (b) (c)

Figura 5.14: *Recreación de una trayectoria vertical al estimular una neurona del* $\mathsf{MMR}_{\mathsf{path}}$ *entrenado.*

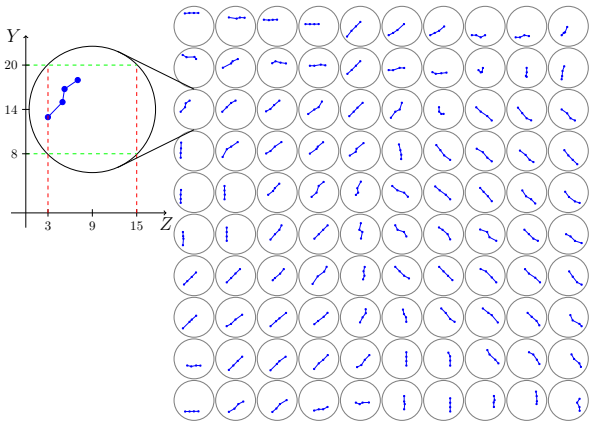

Figura 5.15: *Trayectorias recreadas al estimular las neuronas del* MMR_{path}.

Finalmente, se realizaron trayectorias horizontales (Fig. 5.16), verticales (Fig. 5.17) y diagonales (Fig. 5.18 y Fig. 5.19) sobre la mano del agente y se observó la activación correspondiente en el mapa $\mathsf{MMR}_{\mathsf{path}}$.

En la Fig. 5.16(a) podemos ver 4 diferentes trayectorias horizontales en el plano ZY realizadas por el agente con su correspondiente activación en el $\mathsf{MMR}_{\mathsf{path}}$ (Fig. 5.16(b)).

Por otra parte, en la Fig. 5.17(a) se muestran las trayectorias verticales de

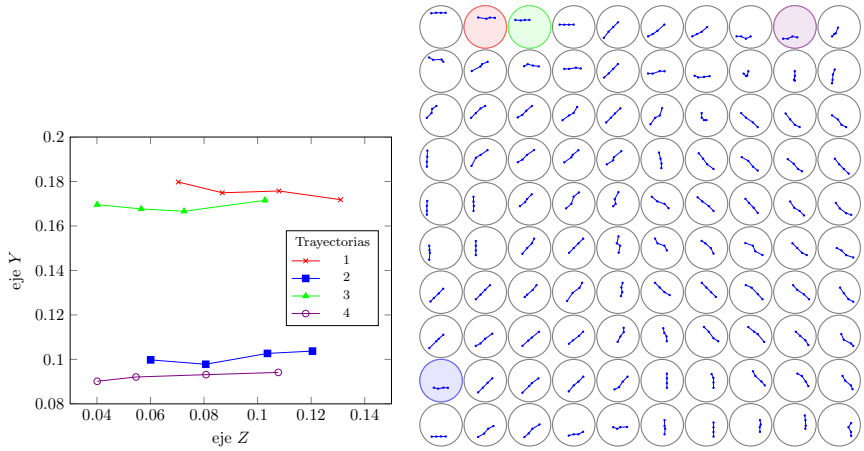

(a) (b)

Figura 5.16: *(a) conjunto de 4 trayectorias horizontales en el plano de movimiento de la mano del agente ZY y (b) su correspondiente activación en el mapa* $\mathsf{MMR}_{\mathsf{path}}$.

la mano del agente, mientras su activación en el $\mathsf{MMR}_{\mathsf{path}}$ se observa en la Fig. 5.17(b).

De la misma manera, en la Fig. 5.18(a) se exhiben trayectorias en diagonal con pendiente positiva, así como las neuronas activas en el $\mathsf{MMR}_{\mathsf{path}}$ (Fig. 5.18(b)).

Finalmente, en la Fig. 5.19(a) se presentan trayectorias en diagonal con pendiente negativa, y las neuronas activas en el $\mathsf{MMR}_{\mathsf{path}}$ (Fig. 5.19(b)).

El sistema construyó una organización instrinseca del espacio de movimientos en el mapa de integración multimodal $\mathsf{MMR}_{\mathsf{path}}$. La estimulación del mapa de representación multimodal permitió la recreación de trayectorias en el espacio motriz.

Este caso de estudio nos permitió observar la organización modal que se genera en la capa superior amodal.

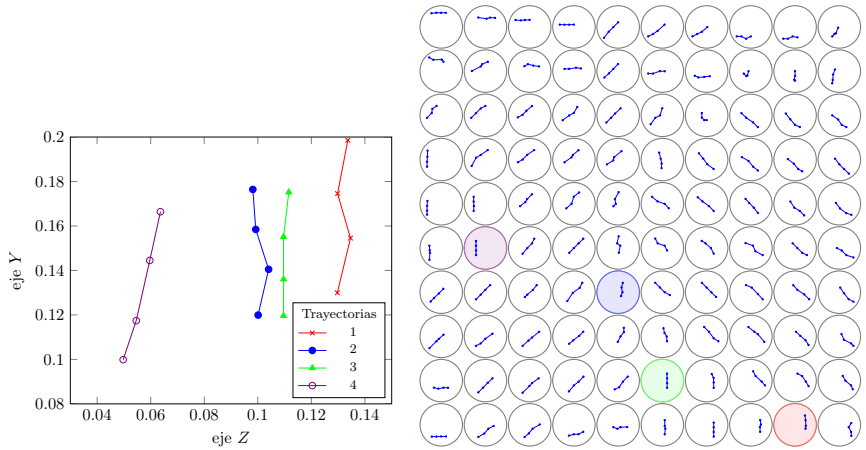

(a) (b)

Figura 5.17: *(a) conjunto de 4 trayectorias verticales en el plano de movimiento de la mano del agente ZY y (b) con su activación en el mapa* $\mathsf{MMR}_{\mathsf{path}}$.

5.3. SOIMA Dinámico

La cuantización vectorial se puede realizar utilizando varios métodos, principalmente variaciones del método k-means (MacQueen et al., 1967), entre estos podemos encontrar el algoritmo de gas neural (NG) (Martinetz, et al., 1993), el de gas neural creciente (GNG) (Fritzke, 1995), o los mapas auto-organizados (SOM) (Kohonen, 1982a). El algoritmo SOM ha sido muy utilizado en el campo de las neurociencias computacionales ya que recrea plausiblemente la característica biológica de la organización de los campos receptivos en las áreas sensoriales donde las neuronas adyacentes comparten representaciones similares. La estabilidad y calidad de tal auto-organización depende fuertemente de una tasa de aprendizaje y una función vecindad decrecientes en el tiempo. Una vez que la fuerza de adaptación ha decaído, la red es incapaz de reaccionar a los cambios subsecuentes en la distribución de los datos de entrada. Esto guarda concordancia al desarrollo de esquemas sensorimotrices de los infantes en sus primeras etapas de la vida, en las cuales se adquieren la mayoría de las propiedades sensoriales y motrices (Law et al., 2011). Sin

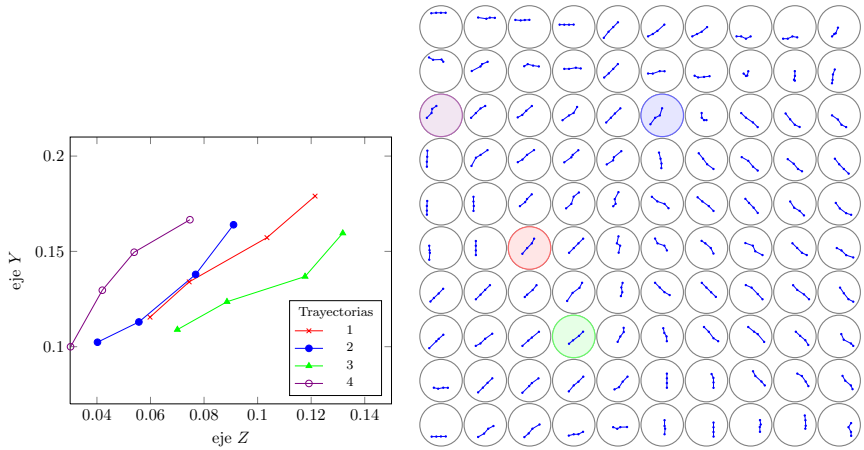

Figura 5.18: *(a) trayectorias diagonales con pendiente positiva, (b) neuronas activadas en el mapa* MMR_{path}.

embargo, deja de lado la plasticidad cortical de las etapas posteriores del desarrollo, es decir la capacidad de la corteza de re-organizarse a si misma debido a lesiones o deficit (Bach-Y-Rita, et al., 1969).

En el trabajo de Rougier et al. (2011) se propusieron los Mapas Auto-Organizados Dinámicos (DSOM), un algoritmo SOM modificado en el cual la tasa de aprendizaje y la función de vecindad no dependen del tiempo. Los autores demostraron como el modelo se adapta dinámicamente a la distribución de los datos de entrada, aun cuando provengan de un entorno cambiante.

Lo que proponemos en este experimento es la construcción de una estructura SOIMA dinámica haciendo uso de DSOM's como unidades constructoras básicas. Como caso de estudio particular proponemos el aprendizaje de un esquema sensorimotriz para la *HEC* utilizando el robot humanoide NAO. Una vez adquirida dicha coordinación, se probará la fiabiliddad de realizar perturbaciones al movimiento del brazo que permita la reorganización de los mapas y la posible adaptación al cambio del esquema sensorimotriz.

La estructura DSOIMA propuesta se puede apreciar en la Fig. 5.20. En cuanto al sistema de coordinación el mapa $\mathsf{M_v}$ corresponde a la entrada visual, el mapa $\mathsf{M_h}$ corresponde a la posición de las articulaciones de la cabeza, el

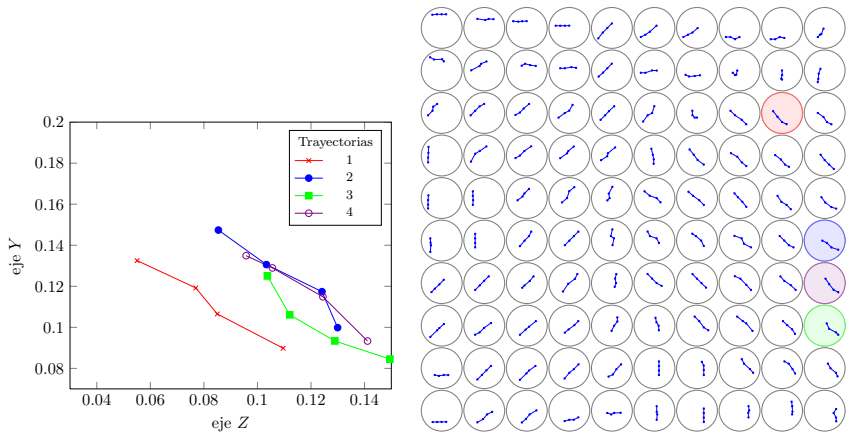

(a) (b)

Figura 5.19: *(a) trayectorias diagonales con pendiente negativa, (b) neuronas activadas en el mapa* $\mathsf{MMR}_{\mathsf{path}}$.

mapa M_{a} codifica las articulaciones del brazo izquierdo del robot y finalmente el $\mathsf{MMR}_{\mathsf{vm}}$ es el mapa en donde se hace la representación multimodal del esquema sensorimotriz.

5.3.1. SOM Dinámicos (DSOM)

El DSOM es un mapa neuronal donde cada neurona i tiene asignada una posición fija p_i en $\mathbb{R}^q$ en la malla, donde q es la dimensión de la malla. El proceso de aprendizaje es un proceso iterativo en el cual se presentan secuencialmente los vectores de entrenamiento v al mapa. Para cada patrón de entrada v, se busca la neurona más cercana en el espacio de entrada de acuerdo a la distancia euclidiana y se le establece como la neurona ganadora s. El vector prototipo w_i de cada neurona i se desplaza hacia v de acuerdo a:

$$\Delta w_i = \epsilon \|v - w_i\| h_\eta(i, s, v)(v - w_i) \tag{5.1}$$

donde ϵ es la tasa de aprendizaje que se mantiene constante y $h_\eta(i, s, v)$ es la función de vecindad de la forma:

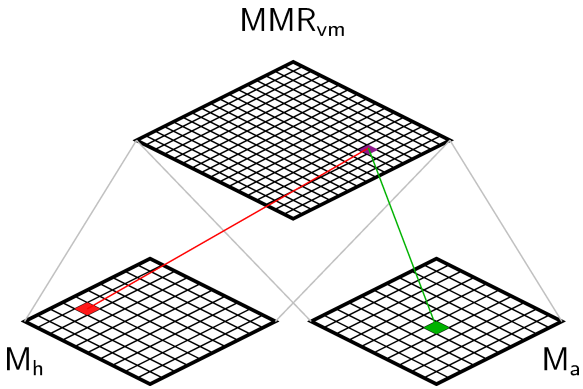

Figura 5.20: *Estructura DSOIMA para la HEC, se muestran 2 mapas modales* $\mathsf{M_h}$ *y* $\mathsf{M_a}$ *para la codificación del espacio propioceptivo de la cabeza y del brazo respectivamente. El mapa superior integra las modalidades codificando el esquema sensorimotriz de en una representación multimodal* $\mathsf{MMR_{vm}}$.

$$h_\eta(i,s,v) = e^{-\frac{1}{\eta^2}\frac{\|p_i - p_s\|^2}{\|v - w_i\|^2}} \tag{5.2}$$

donde η es el parámetro de elasticidad o platicidad, p_i es la posición de la neurona i en la malla y p_s es la posición de la neurona ganadora en la malla. Si $v = w_s$, entonces $h_\eta(i,s,v) = 0$. La idea de estas ecuaciones es que si una neurona esta suficientemente cerca a el patrón de entrada, no hay necesidad de que otras neuronas aprendan y se ajusten, ya que la ganadora representa el patrón. Por otro lado, si ninguna neurona esta cerca del patrón de entrada, cualquier neurona se aprende el patrón de acuerdo a su propia distancia a este.

Conviene hacer notar que en el algoritmo DSOM es importante el parámetro de la elasticidad, el cual modula la fuerza de acoplamiento entre neuronas. Si la elasticidad es muy alta, las neuronas no cubren completamente el espacio de entrada y el algoritmo no converge. Por otra parte, si la elasticidad es muy baja, el acoplamiento entre neuronas es débil y puede entorpecer la auto-organización, pues las neuronas no respetarían la relación de vecindad. El efecto de la elasticidad depende entre otros factores de las condiciones iniciales. Para reducir esta dependencia, la configuración inicial de la red debe cubrir tanto como sea posible la distribución de entrada.

Finalmente cabe mencionar un ajuste en el calculo de la distorsión, la cual es la métrica de calidad del DSOM utilizada. La distorsión en términos simples se calcula como el promedio de las distancias entre cada patrón de entrada y las correspondientes neuronas ganadoras. Debido a la naturaleza dinámica del DSOM no es posible saber de antemano el número de patrones totales para calcular el promedio, por tanto, en nuestro caso utilizaremos solamente la muestra constituida por las últimas 50 observaciones.

5.3.2. Plataforma y entorno experimental

Se utilizó un robot NAO como agente artificial en el simulador Webots. Se construyó un entorno experimental consistente en una arena vacia con el robot NAO en el centro, el cual tiene un marcador fiduciario anclado en la muñeca del brazo izquierdo. Este entorno se puede apreciar en la Fig. 5.3.

A fin de determinar el éxito de la coordinación visuo-motriz se utilizó la cámara situada en la parte inferior de la cabeza del robot con una resolución de 640 × 480 píxeles. Y se doto al agente con la librería ARToolkit para la identificación del marcador fiduciario.

También se utilizaron los 2 grados de libertad de la cabeza del agente (*yaw, pitch*) y 4 grados de libertad del brazo (*shoulder pitch, shoulder roll, elbow yaw, elbow roll*).

5.3.3. Entrenamiento de DSOIMA

Para realizar el entrenamiento del modelo propuesto se construyó un conjunto de patrones con un proceso similar al utilizado en la sección 5.1.2. Dichos patrones están conformados por:

- Los ángulos de las dos articulaciones de la cabeza (*yaw*, *pitch*) como entrada de $\mathsf{M_h}$.
- Las posiciones angulares de las cuatro articulaciones del brazo (*LShoulderPitch*, *LShoulderRoll*, *LElbowYaw*, *LElbowRoll*) como entrada de $\mathsf{M_a}$.

Usamos un DSOM de 30 × 30 para codificar $\mathsf{M_h}$, un DSOM de 30 × 30 para $\mathsf{M_a}$, y finalmente utilizamos un DSOM de 40 × 40 para el $\mathsf{MMR_{vm}}$.

El proceso de entrenamiento de los DSOMs modales $\mathsf{M_a}$ y $\mathsf{M_h}$ se realiza como sigue. Cada instante, la posición actual de las articulaciones del brazo son usadas como vector de entrada en la regla de aprendizaje para el mapa

$\mathsf{M_a}$. Al mismo tiempo, se produce un comando motriz para las articulaciones del cuello de la siguiente manera:

- **Buscar** la neurona ganadora en el DSOM $\mathsf{M_a}$, la cual es la que tenga el vector prototipo más cercano al vector de entrada. El vector de entrada representa la configuración actual de las articulaciones del brazo.
- **Seleccionar** la neurona ganadora en el DSOM $\mathsf{MMR_{vm}}$ de acuerdo al mecanismo de propagación de información en DSOIMA para los mapas amodales.
- **Identificar** la neurona ganadora en el DSOM $\mathsf{M_h}$ como aquella que se encuentra conectada a la neurona ganadora del mapa $\mathsf{MMR_{vm}}$.
- **Enviar** el comando motriz a las articulaciones del cuello correspondientes al vector prototipo de la neurona ganadora en $\mathsf{M_h}$.

En caso de que el efector final del brazo del robot no sea visible en la entrada visual, se considera que la estructura no puede proveer la coordinación visuo-motriz para esa posición específica del brazo.

En este caso, se ejecuta un comando motriz aleatorio sobre las articulaciones del cuello.

El DSOM $\mathsf{M_h}$ es actualizado al igual que el DSOM $\mathsf{M_a}$ con las posiciones de los articulaciones actuales en el cuello y brazo del agente.

En caso de que sea visible la mano del agente en la entrada visual, entonces se activa el aprendizaje de la coordinación visuo-motriz, la cual es capturada por las relaciones representadas en los vectores prototipo de las unidades del DSOM $\mathsf{MMR_{vm}}$.

El aprendizaje del $\mathsf{MMR_{vm}}$ se realiza como sigue:

Se construye un vector con las posiciones topológicas de la neuronas ganadoras en los DSOM $\mathsf{M_a}$ y $\mathsf{M_h}$. La posición topológica se refiere a la posición en la malla del DSOM. Las posiciones de las dos neuronas ganadoras se normalizan a un valor entre $[0, 1]$ y se integran en un solo vector de cuatro elementos.

Este vector se utiliza como entrada para el entrenamiento del DSOM $\mathsf{MMR_{vm}}$ mediante la ecuación de actualización siguiente:

$$\Delta w_i = \epsilon \|v - w_i\| h_\eta(i, s, v)(v - w_i) f_d \tag{5.3}$$

La cual es una variante de la ecuación 5.1, donde f_d es un factor que representa la distancia en el plano de la imagen entre la posición percibida de

la mano del agente al centro de la imagen. Este factor toma el valor de 1 cuando el marcador esta en el centro de la imagen y 0 cuando el marcador se encuentra en una esquina. La idea detrás de este factor es privilegiar al aprendizaje de relaciones sensorimotrices que fomenten la ubicación del marcador en el centro de la imagen.

La métrica utilizada para verificar el correcto entrenamiento de los DSOM correspondió a la distorsión con la aclaración hecha en la sección 5.3.1.

5.3.4. Experimentos y Resultados

El experimento consistió en el agente generando movimientos aleatorios del brazo y moviendo la cabeza de acuerdo a las habilidades de coordinación actuales. El aprendizaje se realizó en linea, esto es, mientras el agente ejecuta los movimientos. Se dejo funcionar el sistema durante 10,000 iteraciones.

La distorsión de los DSOM durante el entrenamiento se muestra en la Fig. 5.21, donde podemos observar como es que esta disminuye a medida que progresa el entrenamiento y el conocimiento de la distribución de los patrones de entrada.

La cobertura de las unidades DSOM a la distribución de los posiciones vistas después de las 10,000 iteraciones se muestra en la Fig. 5.22. Como se puede apreciar las neuronas de los DSOM se han dispersado sobre la distribución de los patrones.

Una de las principales características de DSOIMA es que nos permite modelar un mecanismo básico de plasticidad neuronal. La plasticidad permite el recuperación del sistema a lesiones o cambios estructurales en el agente. En nuestro caso modelamos una lesión en la modalidad propioceptiva de la cabeza después de 10,000 iteraciones. La lesión consistió en un desplazamiento del 10 % en los comandos a las articulaciones *Yaw* y *Pitch* de acuerdo a los rangos establecidos, es decir, in incremento de 3.8 grados en *Yaw* y 7 grados en *Pitch*.

Esta perturbación a los comandos motrices llevó a que el agente no pudiera realizar la coordinación ojo-mano con el esquema sensorimotriz adquirido hasta ese momento. Esto se reflejo en un incremento abrupto en la distorsión del mapa $\mathsf{M_h}$ como se puede apreciar en la Fig. 5.23. La capacidad de los DSOM de adaptarse a la nueva distribución de datos de la cabeza, permitió recuperar la coordinación visuo-motriz, disminuyendo paulatinamente la distorsión del DSOM $\mathsf{M_h}$.

Adicionalmente, en la Fig. 5.24 podemos apreciar el ajuste de las neuronas

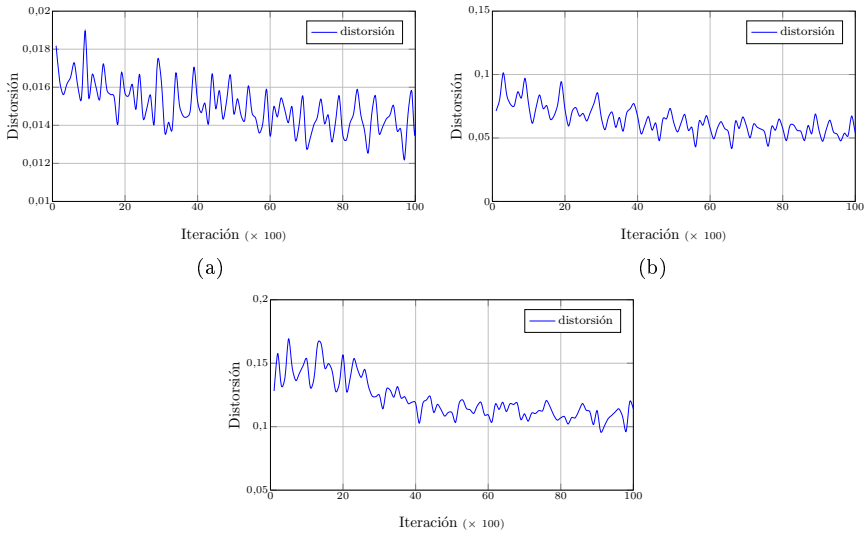

Figura 5.21: *Distorsión de los DSOM durante el entrenamiento; (a) corresponde al DSOM* $\mathsf{M_h}$*, (b) muestra la distorsión del DSOM* $\mathsf{M_a}$ *y por último (c) presenta la distorsión del DSOM* $\mathsf{MMR_{vm}}$*.*

del DSOM *Head* a la nueva distribución de los datos. Aquí podemos ver que aunque la mayoría las neuronas se han ajustado a la nueva distribución aun algunas de ellas conservan el ajuste de la distribución anterior.

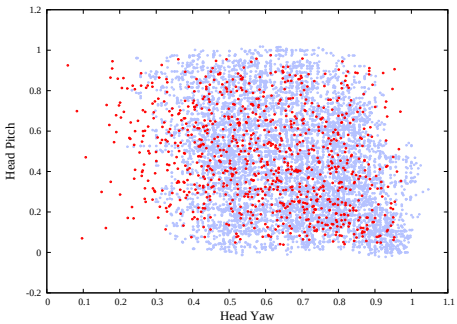

(a)

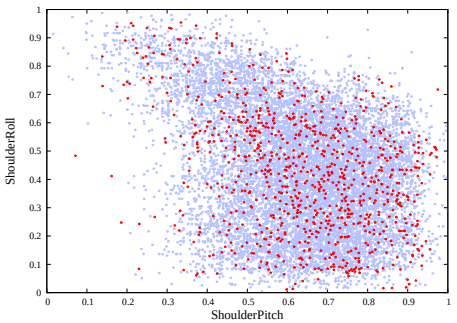

(b)

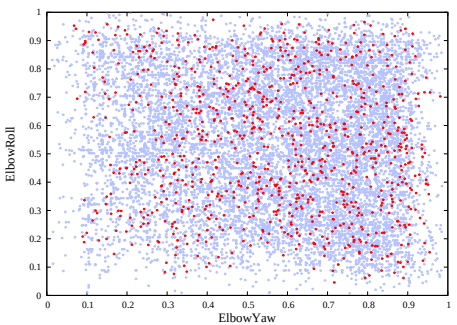

(c)

Figura 5.22: *Cobertura de los DSOM a su correspondiente distribución de datos; los puntos azules muestran la distribución sobre 10k patrones de entrenamiento, mientras los puntos rojos muestran las neuronas de cada DSOM. (a) corresponde al DSOM* $\mathsf{M_h}$*, (b) pertenece al mapa* $\mathsf{M_a}$ *y (c) muestran la cobertura del DSOM* $\mathsf{MMR_{vm}}$*.*

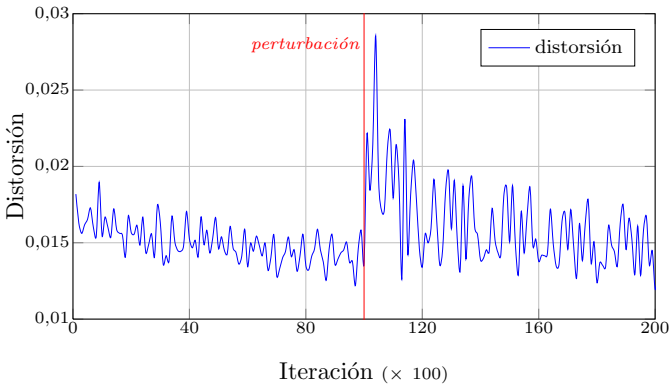

Figura 5.23: *Recuperación de la distorsión del DSOM Head después de la lesión; la lesión se presenta después de 10k patrones.*

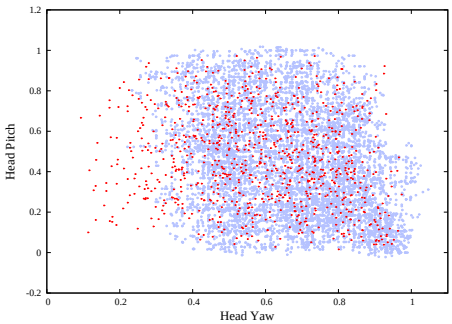

(a)

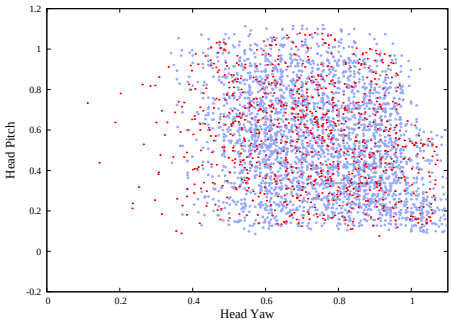

(b)

Figura 5.24: *Ajuste del DSOM Head a la distribución con perturbación; (a) presenta la distribución (puntos azules) y las neuronas (puntos rojos) del DSOM antes de la perturbación, (b) muestra la nueva distribución (puntos azules) y el ajuste de las neuronas (puntos rojos) del DSOM después de la perturbación.*

Capítulo 6
Conclusiones

La relevancia de modelar esquemas sensori-motrices recae en el hecho de que son considerados como la unidad fundamental de análisis de los procesos y habilidades cognitivas bajo la escuela de pensamiento de la robótica cognitiva (Lungarella, et al., 2003). La cognición recae sobre estructuras auto-organizadas que integran la información sensori-motriz. Debido a que los modelos internos crean naturalmente una representación multi-modal de los flujos sensori-motrices, es que han sido ampliamente estudiados como mecanismos adecuados para la integración sensori-motriz.

Basados en estas consideraciones, se propuso una nueva arquitectura computacional (SOIMA), que toma inspiración biológica de las propiedades de auto-organización del cerebro y de la teoría de las zonas de convergencia-divergencia de la corteza cerebral propuesta por (Damasio, 1989) y (Meyer y Damasio, 2009).

A fin de introducir la arquitectura y probar su factibilidad y desempeño, implementamos varios casos de estudio. El primer experimento implementó una estrategia de control de movimientos sacádicos consistente en centrar un estímulo relevante en el espacio sensorial visual usando SOIMA. Este experimento mostró que el enfoque SOIMA permite hacer frente a los problemas de visión con respecto a la dimensionalidad del espacio de entrada. El segundo caso de estudio implementado, una estrategia de cordinación ojo-mano, permitió mostrar como SOIMA puede ser escalado con el fin de modelar tareas cognitivas mas complejas.

SOIMA integra cualidades importantes de aprendizaje en-linea e introduce una manera novedosa de implementar modelos internos no reportada con anterioridad. A pesar de que existe trabajo que muestran redes auto-organizadas acopladas (Hikita, et al., 2008; Lallee y Dominey, 2013; Luciw y Weng, 2010; Morse et al., 2010), nuestra propuesta se encuentra un paso más allá en que modelamos las capacidades de predicción de la maquinaria cognitiva humana a través de los modelos internos. Sin embargo, las actuales arquitecturas de modelos internos muestran algunas dificultades al modelar la cognición bajo las restricciones de la hipótesis de la corporización (por ejemplo, la codificación

independiente de los modelos inverso y directo). Los principales atributos de SOIMA proveen medios para la integración sensori-motriz autónoma, ya que permite a los patrones de activación multi-modal organizarse en una estructura coherente a través de la asociación hebbiana, creando entonces una representación multi-modal cimentada. La capacidad bi-direccional de SOIMA permite a esta representación convertirse en un esquema sensori-motriz disponible tanto como modelo directo (predictivo), como modelo inverso (controlador). La falta de esta propiedad es precisamente una de las principales limitaciones de las arquitecturas cognitivas actuales. Este mecanismo bi-direccional provee, entonces, un sustrato unificado permitiendo un genuino espacio de integración sensori-motriz.

Las cinco principales características que hacen que SOIMA se distinga de las implementaciones actuales de modelos internos y esquemas sensori-motrices se listan a continuación.

- *Modularidad y escalabilidad:* los experimentos reportados ejemplifican el carácter modular de SOIMA. Esta característica redunda en una estrategia de aprendizaje integrada y permite la escalabilidad del sistema. La arquitectura es modular debido a que la estructura lógica del MMR no está pre-establecida, sino que se desarrolla a medida que el agente interactúa con el entorno. Esto a su vez proporciona los medios para la construcción de esquemas sensorimotrices que pueden ser re-enactuados para realizar una tarea en particular. El funcionamiento de la arquitectura permite al sistema aprender en-línea tanto, el MD y como el MI, de una manera integrada. Cuando el agente experimenta el mundo se adquieren nuevos ejemplos de esquemas sensorimotrices; incorporando nuevos conocimientos para su uso posterior. Un primer ejemplo de modularidad del sistema se reporto en el experimento 5.1. Cada nuevo esquema sensorimotriz genera una representación multimodal, codificando un acople particular MI-MD. En consecuencia, diferentes esquemas sensorimotrices pueden ser acoplados para trabajar en conjunto, a fin de incrementar las capacidades sensorimotrices del agente. En este sentido, el sistema es escalable. En resumen, SOIMA debe ser visto como una unidad fundamental para la construcción de estructuras más complejas permitiendo reusar el conocimiento previo.

- *Bidireccionalidad:* dada la codificación interna de las relaciones entre las modalidades sensoriales y motrices, SOIMA trabaja ya sea como modelo directo o modelo inverso. Las conexiones entre los mapas admiten el flujo

bidireccional de información, en consecuencia, la elección del modelo depende de la pregunta y de la entrada disponible. Como se mencionó antes, las actuales implementaciones usan mayormente redes perceptrón multicapa, con una o varias redes codificando el modelo directo y por separado redes codificando el modelo inverso, lo cual obliga a usar diferentes estrategias de aprendizaje para cada modelo. La propuesta aquí presentada sintetiza el modelo acoplado en el mismo sustrato, confiriendo mejoras de conectividad que permiten estrategias de aprendizaje integradas.

- *Temporalidad:* diferentes momentos en el tiempo para la situación sensorial son codificados en el mismo mapa. Las relaciones temporales entre las situaciones son codificadas en las conexiones hebbianas entre los mapas. Como una consecuencia, varios pasos de tiempo pueden ser integrados en el mismo esquema sensorimotriz. Otro aspecto relacionado a la temporalidad es la estabilidad. Es decir, que el sistema sea capaz de hacer frente a las condiciones cambiantes del medio ambiente, esto es, ser estable después de alguna perturbación.

  El ultimo caso de estudio (5.3) aborda esta cuestión implementando los mapas de auto-organización dinámicos DSOM. Estos mapas permiten la reconfiguración del esquema sensorimotriz a largo plazo, si el conocimiento disponible es suficiente para modelar apropiadamente los cambios contingentes de la tarea.

- *Mapeo motriz:* La caracterización de la información contenida en el mapa motriz permite la generación de trayectorias en el espacio motriz. Moviéndonos en el mapa motriz de neurona en neurona se tiene un mapeo en el espacio físico del agente. Esta capacidad es aprovechada en el caso de estudio de caracterización de trayectorias (5.2) para codificar trayectorias en el mapa de representación multimodal.

- *Robustez a la falta de información:* La estructura propuesta puede ser la base para capacidades en las que se carece de cierta información, como es el caso del reconocimiento de acciones. El agente codifica SOIMA basado en su propia experiencia y su propio modelo sensorimotriz; sin embargo, cuando observa la ejecución de una acción alguna fuente de información podría no estar disponible (por ejemplo la información propioceptiva). La falta de esta información no debe representar un problema ya que la activación producida por la entrada disponible se propagaría sobre el resto de la arquitectura.

La primera pregunta planteada en esta tesis fue:

> *¿La creación de asociaciones multimodales puede servir de base para la construcción de esquemas sensorimotrices en un agente?*

En los distintos casos de estudio presentados en los capítulos 4 y 5 se crean funcionales esquemas para distintos comportamientos que combinan modalidades sensoriales y motrices. Estos codificados a través de la representación multimodal que asocia las diferentes modalidades.

La segunda pregunta formulada en esta tesis fue:

> *¿Es posible la creación de una arquitectura que permita la escalabilidad de capacidades sensorimotrices mediante la integración de diferentes esquemas sensorimotrices como módulos constructores?*

En el caso de estudio sobre coordinación visuo-motriz presentado en la sección 5.1 se utilizan dos esquemas que comparten información modal. Estos colaboran en conjunto durante el entrenamiento del sistema así como en la ejecución de la tarea.

Finalmente, la última pregunta de investigación de esta tesis fue:

> *¿Es posible construir un mecanismo que incorpore los cambios en el esquema sensorimotriz debido a factores externos o internos, proveyendo al agente con la capacidad de adaptarse en-linea?*

SOIMA tiene la capacidad de aprender en-linea, lo cual permite adquirir esquemas sensorimotrices cimentados en la interacción del agente con el ambiente de acuerdo a las capacidades específicas del agente. De manera general, la inclusión de mapas dinámicos permitió añadir capacidades básicas de plasticidad. La plasticidad provee al sistema la funcionalidad de incorporar cambios en el agente.

Por su parte, SOIMA abre las puertas a la investigación de la construcción de esquemas sensorimotrices con jerarquías. Dichos esquemas permitirán integrar diferentes niveles de abstracción de las modalidades, es decir que podríamos tener mapas que codifiquen diferentes modalidades sensoriales en un solo mapa sensorial general, y de la misma forma para las modalidades motrices.

Los resultados presentados aquí son alentadores y nos permiten afirmar que la organización y funcionamiento de SOIMA es prometedor para la investigación con modelos internos y su papel en la construcción de esquemas

sensorimotrices. En el contexto de la Cognición Cimentada, consideramos que nuestro trabajo constituye un enfoque computacional biológicamente plausible, efectivo para el desarrollo de modelos complejos de comportamiento cognitivo. Como tal, esperamos que el concepto SOIMA permitirá el estudio y la prueba de diversas hipótesis sobre los procesos que forman la base de la cognición y el desarrollo de agentes artificiales que exhiben un comportamiento coherente en su entorno.

Bibliografía

Arceo, D. C., Escobar, E., Hermosillo, J., y Lara, B. Modelado de un sistema de neuronas espejo en un agente autónomo artificial. *Nova Scientia*, pages 51–72, 2013.

Atkeson, C. G. Learning arm kinematics and dynamics. *Annual review of neuroscience*, 12(1):157–183, 1989.

Bach-Y-Rita, P., Collins, C. C., Saunders, F. A., White, B., y Scadden, L. Vision substitution by tactile image projection. 1969.

Bahill, A. T., Clark, M. R., y Stark, L. Glissades—eye movements generated by mismatched components of the saccadic motoneuronal control signal. *Mathematical Biosciences*, 26(3):303–318, 1975.

Bar, M. The proactive brain: using analogies and associations to generate predictions. *Trends in cognitive sciences*, 11(7):280–289, 2007.

Baranes, A. y Oudeyer, P.-Y. Active learning of inverse models with intrinsically motivated goal exploration in robots. *Robotics and Autonomous Systems*, 61(1):49–73, 2013.

Barsalou, L. Situated simulation in the human conceptual system. *Language and cognitive processes*, 18(5-6):513–562, 2003.

Barsalou, L. W. Grounded cognition. *Annu. Rev. Psychol.*, 59:617–645, 2008.

Bell, C. C. Memory-based expectations in electrosensory systems. *Current opinion in neurobiology*, 11(4):481–487, 2001.

Blakemore, S.-J., Frith, C. D., y Wolpert, D. M. Spatio-temporal prediction modulates the perception of self-produced stimuli. *Journal of cognitive neuroscience*, 11(5):551–559, 1999.

Blakemore, S.-J., Wolpert, D., y Frith, C. Why can't you tickle yourself? *Neuroreport*, 11(11):R11–R16, 2000.

Brandao, M., Jamone, L., Kryczka, P., Endo, N., Hashimoto, K., y Takanishi, A. Reaching for the unreachable: integration of locomotion and whole-body movements for extended visually guided reaching. In *Humanoid Robots (Humanoids), 2013 13th IEEE-RAS International Conference on*, pages 28–33. IEEE, 2013.

Brooks, R. A. Intelligence without representation. *Artificial intelligence*, 47 (1):139–159, 1991.

Cang, J. y Feldheim, D. A. Developmental mechanisms of topographic map formation and alignment. *Annual Review of Neuroscience*, 36(1):51–77, 2013. doi: 10.1146/annurev-neuro-062012-170341. PMID: 23642132.

Clark, A. *Being there: Putting brain, body, and world together again*. MIT press, 1998.

Clark, A. y Grush, R. Towards a cognitive robotics. *Adaptive Behavior*, 7(1): 5–16, 1999.

Cottrell, M., Fort, J.-C., y Pagès, G. Theoretical aspects of the som algorithm. *Neurocomputing*, 21(1):119–138, 1998.

Crapse, T. B. y Sommer, M. A. Corollary discharge circuits in the primate brain. *Current opinion in neurobiology*, 18(6):552–557, 2008a.

Crapse, T. B. y Sommer, M. A. Corollary discharge across the animal kingdom. *Nature Reviews Neuroscience*, 9(8):587–600, 2008b.

Damasio, A. R. The brain binds entities and events by multiregional activation from convergence zones. *Neural Computation*, 1(1):123–132, 1989.

Damasio, A. R. y Damasio, H. Cortical systems for retrieval of concrete knowledge: The convergence zone framework. *Large-scale neuronal theories of the brain*, pages 61–74, 1994.

Daniel, P. y Whitteridge, D. The representation of the visual field on the cerebral cortex in monkeys. *The Journal of physiology*, 159(2):203–221, 1961.

Dautenhahn, K. Roles and functions of robots in human society: implications from research in autism therapy. *Robotica*, 21(04):443–452, 2003.

Dearden, A. y Demiris, Y. Learning forward models for robots. In *IJCAI*, volume 5, page 1440, 2005.

Demiris, Y. y Khadhouri, B. Hierarchical attentive multiple models for execution and recognition of actions. *Robotics and autonomous systems*, 54(5): 361–369, 2006.

Dennett, D. C. *Minds, Machines and Evolution*, chapter Cognitive wheels: The frame problem of AI, pages 129–151. Cambridge University Press, 1984.

Di Paolo, E. A., Barandiaran, X. E., Beaton, M., y Buhrmann, T. Learning to perceive in the sensorimotor approach: Piaget's theory of equilibration interpreted dynamically. *Frontiers in Human Neuroscience*, 8:551, 2014.

Escobar, E., Hermosillo, J., y Lara, B. Self body mapping in mobile robots using vision and forward models. In *Electronics, Robotics and Automotive Mechanics Conference (CERMA), 2012 IEEE Ninth*, pages 72–77. IEEE, 2012.

Fikes, R. E. y Nilsson, N. J. Strips: A new approach to the application of theorem proving to problem solving. *Artificial intelligence*, 2(3-4):189–208, 1971.

Flanagan, J. A. Self-organization in the one-dimensional som with a decreasing neighborhood. *Neural Networks*, 14(10):1405–1417, 2001.

Fort, J.-C. Som's mathematics. *Neural Networks*, 19(6):812–816, 2006.

Franklin, D. W. y Wolpert, D. M. Computational mechanisms of sensorimotor control. *Neuron*, 72(3):425–442, 2011.

Frith, C. D., Wolpert, D. M., et al. Abnormalities in the awareness and control of action. *Philosophical Transactions of the Royal Society of London B: Biological Sciences*, 355(1404):1771–1788, 2000.

Fritzke, B. A growing neural gas network learns topologies, 1995. In *Proc. 1994 NIPS Conf., Denver*, 1995.

Graziano, M. S., Taylor, C. S., Moore, T., y Cooke, D. F. The cortical control of movement revisited. *Neuron*, 36(3):349–362, 2002.

Grodd, W., Hülsmann, E., Lotze, M., Wildgruber, D., y Erb, M. Sensorimotor mapping of the human cerebellum: fmri evidence of somatotopic organization. *Human brain mapping*, 13(2):55–73, 2001.

Grush, R. The emulation theory of representation: Motor control, imagery, and perception. *Behavioral and brain sciences*, 27(03):377–396, 2004.

Harnad, S. The symbol grounding problem. *Physica D: Nonlinear Phenomena*, 42(1):335–346, 1990.

Haruno, M., Wolpert, D. M., y Kawato, M. Mosaic model for sensorimotor learning and control. *Neural computation*, 13(10):2201–2220, 2001.

Haugeland, J. *Artificial intelligence: The very idea*. MIT press, 1985.

Haugeland, J. *Having Thought: Essays in the metaphysics of mind*, chapter Mind embodied and embedded, pages 207–241. Harvard University Press, 1998.

Hebb, D. *The Organization of Behavior A Neuropsychological Theory*. Lawrence Erlbaum Associates, 1949.

Held, R. y Hein, A. Movement-produced stimulation in the development of visually guided behavior. *Journal of comparative and physiological psychology*, 56(5):872, 1963.

Hikita, M., Fuke, S., Ogino, M., Minato, T., y Asada, M. Visual attention by saliency leads cross-modal body representation. In *Development and Learning, 2008. ICDL 2008. 7th IEEE International Conference on*, pages 157–162. IEEE, 2008.

Hoffmann, H. Perception through visuomotor anticipation in a mobile robot. *Neural Networks*, 20(1):22–33, 2007.

Hoffmann, H. y Möller, R. Action selection and mental transformation based on a chain of forward models. *From Animals to Animats*, 8:213–222, 2004.

Hoffmann, M. Minimally cognitive robotics: body schema, forward models, and sensorimotor contingencies in a quadruped machine. In *Contemporary Sensorimotor Theory*, pages 209–233. Springer, 2014.

Hoffmann, M., Marques, H., Hernandez Arieta, A., Sumioka, H., Lungarella, M., y Pfeifer, R. Body schema in robotics: A review. *Autonomous Mental Development, IEEE Transactions on*, 2(4):304–324, Dec 2010. ISSN 1943-0604. doi: 10.1109/TAMD.2010.2086454.

Holst, E. y Mittelstaedt, H. Das reafferenzprinzip. *Naturwissenschaften*, 37 (20):464–476, 1950.

Horowitz, R. y Alvarez, L. Self-organizing neural networks: convergence properties. In *ICNN*, volume 96, pages 7–12, 1996.

Itti, L. y Baldi, P. A principled approach to detecting surprising events in video. In *Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on*, volume 1, pages 631–637. IEEE, 2005.

Itti, L. y Koch, C. A model of saliency-based visual attention for rapid scene analysis. 1998.

Jeannerod, M. Mental imagery in the motor context. *Neuropsychologia*, 33 (11):1419–1432, 1995.

Jeannerod, M. Neural simulation of action: a unifying mechanism for motor cognition. *Neuroimage*, 14(1):S103–S109, 2001.

Jordan, M. I. y Rumelhart, D. E. Forward models: Supervised learning with a distal teacher. *Cognitive science*, 16(3):307–354, 1992.

Kaas, J. H. Topographic maps are fundamental to sensory processing. *Brain Research Bulletin*, 44(2):107 – 112, 1997. ISSN 0361-9230. doi: http://dx.doi.org/10.1016/S0361-9230(97)00094-4. URL http://www.sciencedirect.com/science/article/pii/S0361923097000944.

Kaiser, A., Schenck, W., y Möller, R. Solving the correspondence problem in stereo vision by internal simulation. *Adaptive Behavior*, 21(4):239–250, 2013.

Kawato, M. Internal models for motor control and trajectory planning. *Current Opinion in Neurobiology*, 9(6):718–727, 1999. doi: DOI:10.1016/S0959-4388(99)00028-8.

Kohonen, T. Self-organized formation of topologically correct feature maps. *Biological cybernetics*, 43(1):59–69, 1982a.

Kohonen, T. Clustering, taxonomy, and topological maps of patterns. 1982b.

Kohonen, T. The self-organizing map. *Proceedings of the IEEE*, 78(9):1464–1480, 1990.

Kohonen, T. *Self-Organizing Maps*. Springer, Berlin, 1995.

Kohonen, T. Self-organizing neural projections. *Neural Networks*, 19(6):723–733, 2006.

Kohonen, T. Essentials of the self-organizing map. *Neural Networks*, 37:52–65, 2013.

Kosslyn, S. M., Thompson, W. L., y Ganis, G. *The case for mental imagery*. Oxford University Press, 2006.

Lallee, S. y Dominey, P. F. Multi-modal convergence maps: from body schema and self-representation to mental imagery. *Adaptive Behavior*, page 1059712313488423, 2013.

Lara, B. y Rendon-Mancha, J. M. Prediction of undesired situations based on multi-modal representations. In *Electronics, Robotics and Automotive Mechanics Conference, 2006*, volume 1, pages 131–136. IEEE, 2006.

Law, J., Lee, M., Hülse, M., y Tomassetti, A. The infant development timeline and its application to robot shaping. *Adaptive Behavior*, 19(5):335–358, 2011.

Leigh, R. J. y Zee, D. S. *The Neurology of Eye Movements*. Oxford University Press, third edition, 1999.

Levesque, H. J. y Lakemeyer, G. Cognitive robotics. In *Dagstuhl Seminar Proceedings*. Schloss Dagstuhl-Leibniz-Zentrum fuer Informatik, 2010.

Li, P., Farkas, I., y MacWhinney, B. Early lexical development in a self-organizing neural network. *Neural networks*, 17(8):1345–1362, 2004.

Li, P., Zhao, X., y Mac Whinney, B. Dynamic self-organization and early lexical development in children. *Cognitive Science*, 31(4):581–612, 2007.

Luciw, M. y Weng, J. Top–down connections in self-organizing hebbian networks: Topographic class grouping. *Autonomous Mental Development, IEEE Transactions on*, 2(3):248–261, 2010.

Lungarella, M., Metta, G., Pfeifer, R., y Sandini, G. Developmental robotics: a survey. *Connection Science*, 15(4):151–190, 2003.

MacQueen, J. et al. Some methods for classification and analysis of multivariate observations. In *Proceedings of the fifth Berkeley symposium on mathematical statistics and probability*, volume 1, pages 281–297. Oakland, CA, USA., 1967.

Maravita, A. y Iriki, A. Tools for the body (schema). *Trends in Cognitive Sciences*, 8(2):79 – 86, 2004. ISSN 1364-6613. doi: http://dx.doi.org/10.1016/j.tics.2003.12.008. URL http://www.sciencedirect.com/science/article/pii/S1364661303003450.

Maravita, A. y Spence, C. Multisensory integration and the body schema: Close to hand and within reach. *Current Biology*, pages 531–539, 2003.

Marr, D. *Vision: A computational approach*. Freeman & Co, San Francisco, 1982.

Martinetz, T. M., Berkovich, S. G., y Schulten, K. J. Neural-gas' network for vector quantization and its application to time-series prediction. *Neural Networks, IEEE Transactions on*, 4(4):558–569, 1993.

Mayor, J. y Plunkett, K. A neurocomputational account of taxonomic responding and fast mapping in early word learning. *Psychological Review*, 117(1):1, 2010.

McCarthy, J., Minsky, M. L., Rochester, N., y Shannon, C. E. A proposal for the dartmouth summer research project on artificial intelligence, august 31, 1955. *AI Magazine*, 27(4):12, 2006.

Meltzoff, A. N. y Moore, M. K. Explaining facial imitation: A theoretical model. *Early Development & Parenting*, 6(3-4):179, 1997.

Meyer, K. y Damasio, A. Convergence and divergence in a neural architecture for recognition and memory. *Trends in neurosciences*, 32(7):376–382, 2009.

Miall, R., Weir, D., Wolpert, D. M., y Stein, J. Is the cerebellum a smith predictor? *Journal of motor behavior*, 25(3):203–216, 1993.

Miall, R. C. y Wolpert, D. M. Forward models for physiological motor control. *Neural networks*, 9(8):1265–1279, 1996.

Miller, G. A. The cognitive revolution: a historical perspective. *Trends in cognitive sciences*, 7(3):141–144, 2003.

Mingers, J. Embodying information systems: the contribution of phenomenology. *Information and organization*, 11(2):103–128, 2001.

Möller, R. Perception through anticipation. a behaviour-based approach to visual perception. In *Understanding representation in the cognitive sciences*, pages 169–176. Springer, 1999.

Möller, R. y Schenck, W. Bootstrapping cognition from behavior—a computerized thought experiment. *Cognitive Science*, 32(3):504–542, 2008.

Morse, A. F., Belpaeme, T., Cangelosi, A., y Smith, L. B. Thinking with your body: Modelling spatial biases in categorization using a real humanoid robot. In *Proc. of 2010 annual meeting of the Cognitive Science Society. Portland, USA*, pages 1362–1368, 2010.

Moulton, S. T. y Kosslyn, S. M. Imagining predictions: mental imagery as mental emulation. *Philosophical Transactions of the Royal Society of London B: Biological Sciences*, 364(1521):1273–1280, 2009.

Murphy, R. *Introduction to AI robotics*. MIT press, 2000.

Newell, A. y Simon, H. A. Computer science as empirical inquiry: Symbols and search. *Communications of the ACM*, 19(3):113–126, 1976.

Noë, A. *Action in perception*. MIT press, 2004.

O'Regan, J. K. y Noë, A. A sensorimotor account of vision and visual consciousness. *Behavioral and brain sciences*, 24(05):939–973, 2001.

Oyama, S. *Evolution's eye: A systems view of the biology-culture divide*. Duke University Press, 2000.

Oztop, E., Kawato, M., y Arbib, M. Mirror neurons and imitation: A computationally guided review. *Neural Networks*, 19(3):254–271, 2006.

Pearson, J., Naselaris, T., Holmes, E. A., y Kosslyn, S. M. Mental imagery: functional mechanisms and clinical applications. *Trends in cognitive sciences*, 19(10):590–602, 2015.

Pezzulo, G., Hoffmann, J., y Falcone, R. Anticipation and anticipatory behavior. *Cognitive processing*, 8(2):67–70, 2007.

Pezzulo, G., Barsalou, L. W., Cangelosi, A., Fischer, M. H., McRae, K., y Spivey, M. J. The mechanics of embodiment: A dialog on embodiment and computational modeling. *Embodied and grounded cognition*, page 196, 2011.

Pfeifer, R. y Scheier, C. *Understanding intelligence*. MIT press, 2001.

Ramnani, N. The primate cortico-cerebellar system: anatomy and function. *Nature Reviews Neuroscience*, 7(7):511–522, 2006.

Rizzolatti, G. y Giner, C. S. *Las neuronas espejo: los mecanismos de la empatía emocional*. 2006.

Rochat, P. Self-perception and action in infancy. *Experimental Brain Research*, 123(1-2):102–109, 1998. ISSN 0014-4819. doi: 10.1007/s002210050550. URL http://dx.doi.org/10.1007/s002210050550.

Rochat, P. y Morgan, R. Two functional orientations of self-exploration in infancy. *British Journal of Developmental Psychology*, 16(2):139–154, 1998. ISSN 2044-835X. doi: 10.1111/j.2044-835X.1998.tb00914.x. URL http://dx.doi.org/10.1111/j.2044-835X.1998.tb00914.x.

Rolf, M. y Steil, J. J. Explorative learning of inverse models: a theoretical perspective. *Neurocomputing*, 131:2–14, 2014.

Rougier, N. y Boniface, Y. Dynamic self-organising map. *Neurocomputing*, 74 (11):1840–1847, 2011.

Rynkiewicz, J. Self-organizing map algorithm and distortion measure. *Neural networks*, 19(6):830–837, 2006.

Saegusa, R., Metta, G., Sandini, G., y Sakka, S. Active motor babbling for sensorimotor learning. In *Robotics and Biomimetics, 2008. ROBIO 2008. IEEE International Conference on*, pages 794–799. IEEE, 2009.

Schaal, S. y Schweighofer, N. Computational motor control in humans and robots. *Current opinion in neurobiology*, 15(6):675–682, 2005.

Schenck, W., Hoffmann, H., y Möller, R. Grasping of extrafoveal targets: a robotic model. *New Ideas in Psychology*, 29(3):235–259, 2011.

Schillaci, G., Hafner, V. V., y Lara, B. Coupled inverse-forward models for action execution leading to tool-use in a humanoid robot. In *Proceedings of*

the seventh annual ACM/IEEE international conference on Human-Robot Interaction, pages 231–232. ACM, 2012a.

Schillaci, G., Lara, B., y Hafner, V. Internal simulations for behaviour selection and recognition. In *Human Behavior Understanding*, volume 7559 of *Lecture Notes in Computer Science*, pages 148–160. Springer Berlin Heidelberg, 2012b. ISBN 978-3-642-34013-0.

Schillaci, G., Hafner, V. V., Lara, B., y Grosjean, M. Is that me?: sensorimotor learning and self-other distinction in robotics. In *Proceedings of the 8th ACM/IEEE international conference on Human-robot interaction*, pages 223–224. IEEE Press, 2013.

Searle, J. R. Minds, brains, and programs. *Behavioral and brain sciences*, 3 (03):417–424, 1980.

Seth, A. K. A predictive processing theory of sensorimotor contingencies: explaining the puzzle of perceptual presence and its absence in synesthesia. *Cognitive neuroscience*, 5(2):97–118, 2014.

Shadmehr, R. y Wise, S. P. *The computational neurobiology of reaching and pointing: a foundation for motor learning*. MIT press, 2005.

Suzuki, M., Floreano, D., y Di Paolo, E. A. The contribution of active body movement to visual development in evolutionary robots. *Neural Networks*, 18(5):656–665, 2005.

Szeliski, R. *Computer vision: algorithms and applications*. Springer Science & Business Media, 2010.

Thomas, N. J. T. *Stanford Encyclopedia of Philosophy*, chapter Mental Imagery. 2014.

Traver, V. J. y Bernardino, A. A review of log-polar imaging for visual perception in robotics. *Robotics and Autonomous Systems*, 58(4):378–398, 2010.

Udin, S. B. y Fawcett, J. W. Formation of topographic maps. *Annual Review of Neuroscience*, 11(1):289–327, 1988. doi: 10.1146/annurev.ne.11.030188.001445. PMID: 3284443.

Varela, F., Thompson, E., y Rosch, E. *The Embodied Mind: Cognitive Science and Human Experience*. Cambridge, MA: The MIT Press, 1991.

Vernon, D., Metta, G., y Sandini, G. Embodiment in cognitive systems: on the mutual dependence of cognition & robotics. *cognition*, 8(11):17, 2010.

Vivet, M., Bruneau, J., y Parmentier, C. Learning with micro-robotics activities. integrating advanced technology into education. *spring verlag*, 78: 139–148, 1990.

Webb, B. Neural mechanisms for prediction: do insects have forward models? *Trends in neurosciences*, 27(5):278–282, 2004.

Westerman, G. y Miranda, E. R. Modelling the development of mirror neurons for auditory-motor integration. *Journal of New Music Research*, 31(4):367–375, 2003.

Wilson, M. Six views of embodied cognition. *Psychonomic bulletin & review*, 9(4):625–636, 2002.

Wilson, M. *Handbook of cognitive science: An embodied approach*, chapter How did we get from there to here? An evolutionary perspective on embodied cognition, pages 375–393. Elsevier Burlington, MA, 2008.

Wilson, R. A. y Foglia, L. Embodied cognition. In Zalta, E. N., editor, *The Stanford Encyclopedia of Philosophy*. Spring 2016 edition, 2011.

Wolpert, D. M. y Kawato, M. Multiple paired forward and inverse models for motor control. *Neural Networks*, 11(7):1317–1329, 1998.

Wolpert, D. M., Ghahramani, Z., y Jordan, M. I. An internal model for sensorimotor integration. *Science-AAAS-Weekly Paper Edition*, 269(5232):1880–1882, 1995.

Wolpert, D. M., Miall, R. C., y Kawato, M. Internal models in the cerebellum. *Trends in cognitive sciences*, 2(9):338–347, 1998.

Wolpert, D. M., Ghahramani, Z., y Flanagan, J. R. Perspectives and problems in motor learning. *Trends in cognitive sciences*, 5(11):487–494, 2001.

Wolpert, D. M., Doya, K., y Kawato, M. A unifying computational framework for motor control and social interaction. *Philosophical Transactions of the Royal Society of London B: Biological Sciences*, 358(1431):593–602, 2003.

Yamashita, Y. y Tani, J. Spontaneous prediction error generation in schizophrenia. *PloS one*, 7(5):e37843, 2012.

Ziemke, T. Rethinking grounding. In *Understanding representation in the cognitive sciences*, pages 177–190. Springer, 1999.