



UNIVERSIDAD AUTÓNOMA DEL
ESTADO DE MORELOS



UNIVERSIDAD AUTÓNOMA DEL ESTADO DE
MORELOS

FACULTAD DE HUMANIDADES

Control de un Agente Artificial usando
Aprendizaje Autónomo

T E S I S

QUE PARA OBTENER EL TÍTULO DE:
Maestría en Ciencias Cognitivas

PRESENTA:
Diana Valenzo Macías

DIRECTOR DE TESIS:
Bruno Lara Guzmán

19 de Enero, 2015

Índice general

CAPÍTULO

1. Introducción	1
1.1. Preguntas de investigación	1
1.2. Enfoque del proyecto	2
1.2.1. Inteligencia Artificial	2
1.2.2. Robótica cognitiva	3
1.2.3. Sistemas Híbridos	4
1.3. Estructura de la Tesis	4
2. Neuronas biológicas	7
2.1. Potenciales de acción	8
2.2. Sinapsis neuronal	10
2.3. Plasticidad sináptica	11
3. Cultivos neuronales embebidos	13
3.1. Arreglo de Multi-Electrodos	14
3.2. Neurociencia e Inteligencia artificial	16
3.3. Simulaciones de cultivos neuronales	17
4. Redes neuronales artificiales de potenciales de acción	19
4.1. Redes Neuronales Artificiales bioinspiradas	19
4.2. Modelo de neurona de Izhikevich	21
4.3. Redes neuronales artificiales embebidas	23
5. Diseño de agentes reactivos	27
5.1. Agente artificial	27
5.2. Modelo de Neurona	28
5.3. Agentes reactivos	29
5.3.1. Evasión de dos obstáculos	32
5.3.2. Evasión y giro	38

6. Aprendizaje autónomo de evasión de obstáculos	43
6.1. Arquitectura con interneuronas	45
6.2. Arquitectura completamente conectada	55
7. Conclusiones	67

Índice de figuras

2.1.	Esquema de dos neuronas piramidales conectadas.	7
2.2.	Potencial de acción.	8
3.1.	Agente virtual controlado neuronalmente.	14
3.2.	Arreglo de multielectrodos.	15
4.1.	Modelos de neurona de potenciales de acción.	20
4.2.	Diferentes comportamientos neuronales.	22
4.3.	Red neuronal acoplada con el robot.	24
5.1.	Agente artificial Pioneer 3DX	28
5.2.	Muestra del entorno simulado durante los experimentos.	28
5.3.	Sistemas reactivos capaces de evadir obstáculos.	29
5.4.	Transmisión de la información en los sistemas reactivos.	32
5.5.	Evasión de dos obstáculos.	33
5.6.	Registro de sonares y neuronas sensoriales del lado izquierdo.	35
5.7.	Registro de sonares y neuronas sensoriales del lado derecho.	36
5.8.	Registro de la actividad de las interneuronas y neuronas motoras.	37
5.9.	Medio giro del agente artificial.	38
5.10.	Actividad de sonares y neuronas sensoriales del lado izquierdo.	39
5.11.	Actividad de sonares y neuronas sensoriales del lado derecho.	40
5.12.	Actividad de las neuronas motoras.	41
6.1.	Sistemas artificiales utilizados para el aprendizaje.	43
6.2.	Sistema experimental 1	45
6.3.	Recorrido del agente artificial durante el experimento 1.	47
6.4.	Registro de la actividad neuronal durante la Colisión 1.	48
6.5.	Registro de la actividad neuronal durante la Colisión 3.	49
6.6.	Patrón de activación simultánea de las 4 neuronas.	50
6.7.	Modulación de los pesos sinápticos durante el experimento 1.	51
6.8.	Dos tipos de activación.	52
6.9.	Actividad neuronal registrada después de las seis colisiones.	53
6.10.	Navegación del agente después del aprendizaje.	54
6.11.	Sistema experimental 2	55

6.12.	Recorrido del agente artificial durante el experimento 2.	56
6.13.	Actividad neuronal (lado izquierdo) durante la Colisión 1.	58
6.14.	Actividad neuronal (lado derecho) durante la Colisión 1.	60
6.15.	Actividad neuronal (lado izquierdo) durante la Colisión 4.	61
6.16.	Actividad neuronal (lado derecho) durante la Colisión 4.	62
6.17.	Modulación de los pesos sinápticos durante el experimento 2.	63
6.18.	Modulación de los pesos sinápticos durante el experimento 2.	63
6.19.	Modulación de los pesos sinápticos durante el experimento 2.	64
6.20.	Modulación de los pesos sinápticos durante el experimento 2.	64
6.21.	Recorrido del agente con los pesos sinápticos finales.	65

Índice de cuadros

5.1. Parámetros para simular neuronas excitatorias	29
6.1. Pesos sinápticos iniciales durante el experimento 1.	46
6.2. Pesos sinápticos iniciales y finales en el experimento 1.	51
6.3. Pesos sinápticos iniciales durante el experimento 2.	55
6.4. Pesos sinápticos finales del experimento 2.	59

RESUMEN

Control de un Agente Artificial usando Aprendizaje Autónomo

Diana Valenzo Macías

En este proyecto se realizaron simulaciones de un proceso de aprendizaje autónomo de un agente artificial controlado mediante redes neuronales artificiales de potenciales de acción durante una tarea de evasión de obstáculos. Se implementó el modelo simple de neurona de potenciales de acción de Izhikevich et al. (2003), que es capaz de reproducir los cambios abruptos del potencial de membrana de las neuronas biológicas, conocidos como potenciales de acción. La estrategia de aprendizaje está basada en un proceso de asociación multimodal y los pesos sinápticos de las redes fueron modificados mediante una regla de aprendizaje hebbiano. El proyecto está enmarcado dentro de la Robótica cognitiva y está inspirado en la metodología de los cultivos neuronales embebidos. Este enfoque experimental tiene como objetivo *corporizar* cultivos de neuronas biológicas en agentes artificiales, con la finalidad de estudiar la dinámica neuronal tomando en cuenta la interacción del agente con su entorno. A pesar del creciente interés generado por las redes neuronales artificiales de potenciales de acción, existen pocas investigaciones que implementen estos modelos para el control y el aprendizaje de agentes autónomos. El presente trabajo está orientado hacia la generación de conocimiento acerca de los algoritmos computacionales de aprendizaje de redes neuronales artificiales de potenciales de acción embebidas en un entorno a través de un agente artificial.

Introducción

El diseño y construcción de agentes artificiales que sean capaces de interactuar con su entorno de manera autónoma ha sido de gran interés dentro de la Robótica cognitiva. En este proyecto se desea explorar un proceso de aprendizaje autónomo de un agente artificial durante una tarea de evasión de obstáculos. La estrategia experimental está basada en simular un proceso de asociación multimodal en una red neuronal artificial acoplada a un agente artificial simulado. Los pesos sinápticos de las redes son modificados mediante la implementación de una regla de aprendizaje hebbiano.

Recientemente, han sido propuestos diversos modelos matemáticos de neurona que son capaces de reproducir los cambios abruptos del potencial de membrana de las neuronas biológicas, conocidos como señales eléctricas o potenciales de acción. Estos modelos han sido denominados modelos de neurona de potenciales de acción (Maass, 1997; Izhikevich, 2004). En este proyecto se implementó el modelo simple de neurona de potenciales de acción propuesto por Izhikevich et al. (2003) debido a su plausibilidad biológica y eficiencia computacional. Este modelo es capaz de reproducir diferentes comportamientos neuronales reportados experimentalmente únicamente a partir de cuatro parámetros (Izhikevich et al., 2003).

Las redes neuronales artificiales de potenciales de acción han generado gran interés en áreas como la Neurociencia computacional. Sin embargo, existen pocas investigaciones que implementen estos modelos para el control y aprendizaje de agentes artificiales autónomos. La finalidad de esta tesis es generar conocimiento acerca de los algoritmos computacionales de aprendizaje autónomo de redes neuronales artificiales de potenciales de acción embebidas en un entorno a través de un agente artificial.

1.1. Preguntas de investigación

Las preguntas de investigación que se desean responder con esta tesis son:

- ¿Es posible simular un proceso de aprendizaje en una red neuronal artificial de potenciales de acción?
- ¿Es posible simular un proceso de asociación multimodal en una red de neuronas de potenciales de acción?
- ¿El proceso de asociación multimodal puede ser capaz de generar un comportamiento coherente en un agente artificial?

1.2. Enfoque del proyecto

Este proyecto está enmarcado dentro de la Robótica cognitiva, que forma parte de la nueva Inteligencia Artificial, y está inspirado en la metodología de los cultivos neuronales embebidos, la cual se centra en el diseño de sistemas neuro-robóticos o híbridos. La idea general de cada uno de estos enfoques se describe a continuación.

1.2.1. Inteligencia Artificial

La Inteligencia Artificial (IA) surge con el objetivo de tratar de reproducir la inteligencia en máquinas, bajo la hipótesis de que *“todos los aspectos del aprendizaje, o cualquier otra característica de la inteligencia, pueden en principio ser tan precisamente descritos, que una máquina puede ser hecha para simularlos”* (McCarthy et al., 2006). Los primeros esfuerzos dentro de este campo de investigación se centraron en hacer posible que las máquinas usaran lenguaje, fueran capaces de formar conceptos y resolvieran problemas abstractos reservados únicamente para los humanos hasta ese momento (McCarthy et al., 2006). Esta etapa de la IA, denominada etapa clásica o tradicional, estuvo fuertemente influenciada por la hipótesis del *cognitivismo*, un paradigma dentro de las Ciencias cognitivas que afirma que la cognición humana está basada en la manipulación de representaciones simbólicas mediante reglas (Newell and Simon, 1976).

A pesar de ser la visión predominante en ese tiempo, la idea de que el comportamiento inteligente puede ser capturado únicamente en términos simbólicos ha sido fuertemente criticada desde sus inicios. Hubert Dreyfus, uno de

los filósofos críticos más reconocidos de la IA, no creía imposible la generación de máquinas inteligentes, pero enfatizaba la necesidad de diseñar agentes artificiales *situados* en el mundo, dando importancia al rol del cuerpo para el comportamiento inteligente (Dreyfus, 1967, 1972). La IA clásica ha sido exitosa en algunos dominios bien definidos, como en la generación de algoritmos lógicos capaces de solucionar problemas abstractos. No obstante, este enfoque no ha podido generar sistemas artificiales que sean capaces de imitar habilidades humanas más básicas, como los procesos sensorimotrices o la percepción (Mingers, 2001).

Propuestas concordantes con las ideas de Dreyfus comenzaron a debilitar a la IA clásica y germinaron los fundamentos de un paradigma alternativo denominado nueva Inteligencia Artificial (nueva IA). En contraste con la visión clásica, la nueva IA se trazó como objetivo diseñar y construir inteligencia *corporizada* y *situada* en el mundo. Este enfoque de la IA se apoya en los paradigmas *corporizado* y *embebido* de la cognición, los cuales enfatizan la importancia de la interacción del agente con su entorno para el desarrollo de los procesos cognitivos (Pfeifer and Scheier, 1999).

Uno de los pioneros de la nueva IA es Rodney Brooks quien, al igual que Moravec (Moravec, 1984), consideraba que el desarrollo de agentes móviles autónomos era la manera adecuada de enfocar el problema de la inteligencia en máquinas. Para Brooks, la percepción y las habilidades motrices son los problemas realmente difíciles a resolver por los sistemas inteligentes. Brooks afirmaba que la resolución de problemas, el lenguaje, el conocimiento experto y su aplicación son bastante “simples” una vez que las habilidades para sentir y moverse en un ambiente dinámico se han desarrollado lo suficiente para lograr la supervivencia y reproducción de los organismos (Brooks, 1991).

1.2.2. Robótica cognitiva

Siguiendo la misma línea de pensamiento que la nueva IA, la Robótica cognitiva es un campo de investigación que postula que la mejor manera de imitar la cognición en máquinas es mediante la construcción de agentes artificiales autónomos que se encuentren en constante interacción con su entorno. Esta disciplina ha centrado su atención en el diseño y construcción de robots o agentes artificiales autónomos que sean capaces de realizar alguna tarea cognitiva determinada. El término “autónomos” hace énfasis a la capacidad de funcionamiento exitoso de los agentes artificiales únicamente a partir de su interacción con el entorno, desvinculando lo más posible al diseñador del control

del agente artificial (Pfeifer and Scheier, 1999).

Generalmente, los agentes artificiales son robots móviles que tienen un cuerpo dotado con sensores y un sistema motor, componentes que les permiten *percibir* su entorno e interactuar con su mundo. Los agentes artificiales pueden ser reales, es decir, robots móviles físicos, o pueden ser agentes simulados computacionalmente (Pfeifer and Scheier, 1999).

Los estudios desarrollados en este campo se enfocan en niveles de inteligencia simples, como moverse exitosamente en un ambiente. Su hipótesis central es que la inteligencia, expresada como un comportamiento complejo, emerge de la interacción de comportamientos más simples, como la evasión de obstáculos (Copeland, 1993).

1.2.3. Sistemas Híbridos

Una de las aplicaciones de los agentes artificiales dentro de las Ciencias cognitivas es simular procesos cognitivos mediante la implementación de modelos desarrollados en otras disciplinas como la Biología, la Psicología y las Neurociencias (Pfeifer and Scheier, 1999). Sin embargo, recientemente ha surgido una metodología novedosa para el control de agentes artificiales autónomos, que surge a partir de la fusión de la Robótica y la Neurociencia cognitiva. Este paradigma metodológico ha sido denominado Neuro-Robótica o cultivos neuronales embebidos y tiene como objetivo *re-corporizar* cultivos de neuronas biológicas en agentes artificiales, ya sea robóticos o simulados. La idea general de este enfoque es controlar a los agentes artificiales neuronalmente mediante cultivos de neuronas *in vitro*. La finalidad de los cultivos neuronales embebidos es poder estudiar la dinámica neuronal del cultivo cuando está expuesta al ambiente a través del agente. Asimismo, esta metodología pretende estudiar procesos cognitivos, como el aprendizaje y la memoria *in vitro*, a partir de la integración de la conducta observable de los agentes artificiales y los estudios de los mecanismos celulares relacionados con estos procesos cognitivos (DeMarse et al., 2001).

1.3. Estructura de la Tesis

Los siguientes capítulos de la Tesis están estructurados de esta manera:

En el capítulo 2 se proporciona una breve introducción de las neuronas, se describen sus principales características morfológicas y su funcionamiento.

to. Este apartado tiene la finalidad de esclarecer los capítulos posteriores y es útil para explicar el tipo de resultados obtenidos en los experimentos realizados. En el capítulo 3 se profundiza en la propuesta metodológica de los cultivos neuronales embebidos. Se describe el tipo de técnica de registro de actividad celular que se requiere, así como los alcances y limitaciones de este nuevo enfoque dentro de las Neurociencia Cognitiva. El capítulo 4 introduce algunas herramientas computacionales bioinspiradas que pueden resultar de utilidad para la Neurociencia experimental. En este apartado se describen las redes neuronales artificiales de potenciales de acción y el modelo simple de neurona de Izhikevich et al. (2003). Además, se describe el experimento de aprendizaje reportado por Scheier et al. (1998), en el cual están inspirados los sistemas artificiales diseñados para los experimentos de aprendizaje realizados en el presente trabajo. En los capítulos 5 y 6 se muestra una forma de implementar algunas herramientas computacionales bioinspiradas para lograr que un agente simulado sea capaz de evadir obstáculos. En particular, en el capítulo 5 se describe el agente artificial utilizado y el tipo de comportamiento neuronal simulado durante los experimentos. También se presentan dos sistemas artificiales reactivos capaces de evadir obstáculos y los resultados de dos experimentos. Finalmente, en el capítulo 6 se muestran las arquitecturas diseñadas para simular el aprendizaje de evasión de obstáculos, así como la estrategia y los parámetros de la regla de Hebb implementados. Asimismo, los resultados obtenidos con cada arquitectura son presentados en este capítulo. Las conclusiones globales del proyecto se presentan en el último capítulo.

CAPÍTULO 2

Neuronas biológicas

Las neuronas son las unidades básicas de procesamiento del sistema nervioso. Este tipo de células son únicas debido a que sólo ellas son capaces de transmitir señales eléctricas a través de distancias largas. Las neuronas conforman un grupo heterogéneo de células, de las cuales sólo cerca de 50 tipos han sido descritos hasta ahora. A pesar de ello, todas las neuronas presentan características comunes que las distinguen de otras células. Es posible identificar cuatro regiones morfológicas definidas en las neuronas y cada una tiene un rol distinto en la generación y transmisión de señales eléctricas (Kandel et al., 2000).

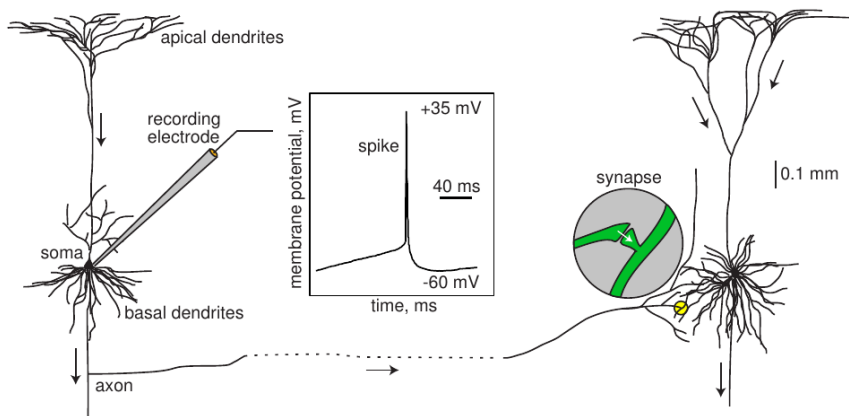


Figura 2.1: Esquema de dos neuronas piramidales conectadas y un potencial de acción registrado experimentalmente (Izhikevich, 2007).

El cuerpo celular o soma, es el centro metabólico de la célula. En esta región se encuentra el núcleo y el retículo endoplásmico, maquinaria celular necesaria para la síntesis de proteínas. A partir de esta estructura se generan varias ramificaciones cortas denominadas dendritas, así como una ramificación tubular larga denominada axón. Las dendritas reciben señales eléctricas provenientes de otras células nerviosas y las dirigen hacia el soma. Por otro lado, el axón se extiende lejos del cuerpo celular (desde 0.1 mm hasta 3 m) y es la unidad principal conductora de señales eléctricas hacia otras neuronas. En su región terminal, el axón de las neuronas se divide en ramificaciones muy finas denominadas terminaciones presinápticas. Estas estructuras son los sitios de comunicación con otras células (Kandel et al., 2000).

2.1. Potenciales de acción

Las señales eléctricas denominadas potenciales de acción son impulsos nerviosos rápidos, transitorios, todo-o-nada, que presentan una amplitud de 100 mV y una duración de 1 ms aproximadamente. Estas señales se inician en una región específica denominada *Hillock*, ubicada en el segmento inicial del axón, cerca del soma. Los potenciales de acción se conducen a tasas de 1-100 m/s a lo largo del axón (Kandel et al., 2000).

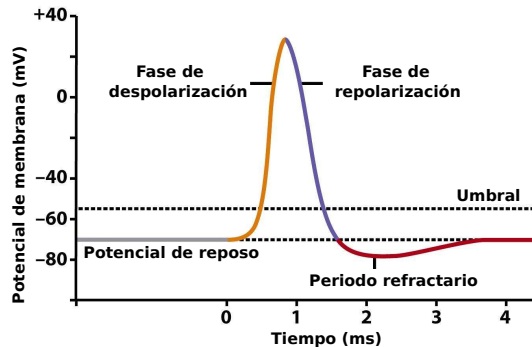


Figura 2.2: Potencial de Acción. Figura adaptada de Freeman and Hamilton (2005).

Típicamente, los axones están recubiertos de una vaina aislante de mielina, lo que produce un aumento en la velocidad de conducción de los potenciales de acción. La vaina de mielina se interrumpe en intervalos regulares denominados nodos de Ranvier. Es en estos puntos donde el potencial de acción es regenerado a lo largo del axón (Kandel et al., 2000).

Las características excitables de las neuronas se explican por las propiedades eléctricas de sus membranas plasmáticas. Cada neurona presenta una separación de cargas a través de su membrana. En estado de reposo, una célula tiene un exceso de cargas positivas al exterior de su membrana y un exceso de cargas negativas en su interior. Esta separación de cargas genera una diferencia de potencial eléctrico o voltaje, denominado potencial de membrana, que ha sido definido como:

$$V_m = V_i - V_o \quad (2.1)$$

donde V_i representa el voltaje en el interior de la célula y V_o el voltaje en el exterior. Por convención, se ha establecido que el potencial fuera de la célula corresponde a cero. Generalmente, el potencial de membrana de una neurona en reposo es de -65 mV, aunque este valor puede variar en diferentes células neuronales de -40 a -80 mV (Kandel et al., 2000).

Un incremento en el potencial de membrana (desde -65 hasta -55 mV, por ejemplo) se denomina despolarización. En contraste, una disminución en el potencial (desde -65 hasta -75 mV) se conoce como hiperpolarización. Una despolarización arriba de un valor umbral genera siempre un potencial de acción. La diferencia de potencial de membrana resulta de dos factores principalmente: *a*) de la distribución desigual de iones cargados eléctricamente a través de la membrana celular y, *b*) de la permeabilidad selectiva a potasio (K^+) (Kandel et al., 2000).

Los cuatro iones más importantes que afectan el potencial de membrana son sodio (Na^+), potasio (K^+), cloruro (Cl^-) y algunos aniones orgánicos (A^-). Los iones Na^+ y Cl^- son los más abundantes en el exterior de la célula, mientras que existe una mayor concentración de K^+ y aniones orgánicos (A^-) dentro de ella. El potencial de acción se genera por el flujo de estos iones a través de canales dependientes de voltaje presentes en la membrana plasmática (Kandel et al., 2000).

Hodgkin and Katz (1949), propusieron que la despolarización de una célula por arriba de su umbral causaba un aumento en la permeabilidad de la mem-

brana a Na^+ , indicando que la entrada de este ión a la célula provocaba la fase creciente del potencial de acción. La entrada de Na^+ es seguida por una salida de K^+ , la cual desencadena la repolarización de la membrana durante la fase decreciente del potencial de acción (Hodgkin and Katz, 1949). En muchas células nerviosas, el potencial de acción es seguido de una hiperpolarización, que ocurre debido a que los canales de K^+ que se abren durante la fase tardía del potencial de acción permanecen abiertos aún cuando ya se ha llegado al potencial de membrana de reposo. Después del potencial de acción se produce un periodo refractario, característico por una disminución de la excitabilidad celular. Este periodo se divide en una fase absoluta, donde resulta imposible excitar a la célula, y una fase relativa, donde es posible desencadenar un potencial de acción únicamente a partir de estímulos muy fuertes (Kandel et al., 2000).

Hodgkin and Huxley (1939) fueron los primeros en obtener un registro de la dinámica de un potencial de acción en el axón gigante de calamar, utilizando un electrodo de vidrio como instrumento de medición. A partir de sus observaciones experimentales, desarrollaron un modelo matemático del comportamiento neuronal, el cual fue validado posteriormente. Su modelo matemático consiste en un sistema de cuatro ecuaciones y decenas de parámetros que describen el potencial de membrana, la activación de las corrientes de Na^+ y K^+ , así como la inactivación de la corriente de Na^+ (Izhikevich, 2004).

2.2. Sinapsis neuronal

Los sitios de comunicación entre las neuronas se denominan sinapsis. Como se ha mencionado anteriormente, las terminaciones presinápticas son estructuras que permiten la comunicación con otras células. La neurona que transmite el impulso nervioso se conoce como neurona presináptica, mientras que la neurona que recibe la señal se denomina neurona postsináptica. Esto quiere decir que los impulsos nerviosos o potenciales de acción se conducen sólo en una dirección (Kandel et al., 2000).

Existen dos formas en las que una neurona puede transmitir los potenciales de acción a otra célula. Dependiendo de la estructura sináptica establecida entre ambas células, las sinapsis han sido clasificadas en sinapsis químicas y eléctricas. En las sinapsis químicas, las neuronas se encuentran separadas por el espacio o hendidura sináptica (20-30 nm). En este tipo de sinapsis, el potencial de acción o impulso eléctrico se transmite indirectamente entre ambas células

mediante liberación de neurotransmisores. En contraste, las sinapsis eléctricas son formadas por uniones de comunicación entre las membranas plasmáticas de las dos neuronas. Debido a que en este tipo de sinapsis existe contacto directo entre las células, la transmisión del impulso eléctrico se da de manera directa (Kandel et al., 2000).

2.3. Plasticidad sináptica

La plasticidad sináptica se refiere a la propiedad de las sinapsis de sufrir cambios estructurales y funcionales. Es una capacidad adaptativa del sistema nervioso (Kleim and Jones, 2008). Existen diversos tipos de plasticidad sináptica. No obstante, en este trabajo nos centraremos en un tipo particular de sinapsis que se considera la base neuronal de procesos como el aprendizaje y la memoria (Feldman, 2012). En la siguiente subsección se define el aprendizaje y se relaciona a este proceso cognitivo con su substrato neuronal.

Aprendizaje y plasticidad neuronal

Una de las formas más poderosas en las que el ambiente influye en nuestra conducta es a través del aprendizaje, que ha sido definido como un proceso por el que ocurren cambios relativamente permanentes en el comportamiento como resultado de la experiencia. El aprendizaje es un constructo hipotético, por lo que no puede ser directamente observado y sólo se infiere a partir del comportamiento (Gross and Humphreys, 1992).

En Biología, las conductas consideradas como aprendidas varían desde las más simples, como la habituación, hasta conductas más complejas, como el aprendizaje asociativo. La habituación se refiere a la pérdida de respuesta ante un estímulo que contiene poca o nula información relevante para el organismo. Por otro lado, el aprendizaje asociativo es la habilidad de los animales de asociar dos estímulos, por ejemplo un color con un sabor desagradable (Reece et al., 2011). El condicionamiento clásico y el condicionamiento operante son ejemplos de este tipo de aprendizaje.

A nivel celular, el aprendizaje depende de los mecanismos de plasticidad neuronal (Verhoog et al., 2013). Actualmente, se piensa que el aprendizaje es mediado por una modificación de los circuitos neuronales que es dependiente de la experiencia (Caporale and Dan, 2008). Este tipo de modificación neuronal se denomina plasticidad sináptica asociativa, en la que activaciones simultáneas o secuenciales de dos neuronas conectadas entre sí lleva a un cambio en la fuerza

sináptica que existe entre ellas (Feldman, 2012). El primer postulado de una regla de aprendizaje a nivel neuronal fue propuesto por Donald Hebb en 1949 y establece lo siguiente:

“Cuando el axón de una célula A se encuentra lo suficientemente cerca de una célula B y repetida y persistentemente participa en hacerla disparar, entonces, algún proceso de crecimiento o cambio metabólico ocurre en una o ambas células, de tal manera que la eficiencia de A para hacer disparar a B incrementa” Hebb (2002).

Este postulado recibió sustento experimental a partir del descubrimiento de la Potenciación de Largo Plazo (*Long-term Potentiation*, LTP) de la transmisión sináptica, así como con el descubrimiento de la Depresión de Largo Plazo (*Long-term Depression*, LTD). Generalmente, la LTP es inducida mediante estimulación de alta o baja frecuencia de neuronas presinápticas asociada con una fuerte despolarización de neuronas postsinápticas. Por otro lado, la LTD se induce por estimulación de baja frecuencia de la neurona acoplada a una débil despolarización de la neurona postsináptica. Ambos fenómenos desencadenan la modificación sináptica entre neuronas, por lo que se piensa que tanto la LTP como la LTD son candidatas prometedoras *“para servir como las bases sinápticas del aprendizaje y la memoria”* (Bliss et al., 1993; Siegelbaum and Kandel, 1991; Caporale and Dan, 2008).

Cultivos neuronales embebidos

La metodología de los cultivos neuronales embebidos surge en respuesta a la brecha explicativa entre los estudios conductuales de aprendizaje y memoria y los estudios *in vitro* de los mecanismos celulares de plasticidad sináptica relacionados con estos procesos cognitivos (DeMarse et al., 2001). Esta metodología es un intento de integración de los enfoques *top down* (cognitivo, conductual, etológico) y *bottom up* (celular, molecular) para estudiar el aprendizaje y la memoria (Potter, 2001; Manson, 2004).

Este paradigma metodológico se interesa por el estudio de sistemas neuronales *híbridos* que están en constante interacción con el entorno. La estrategia que propone este enfoque es *re-corporizar* cultivos neuronales biológicos a través de agentes o robots autónomos reales o simulados. La idea general es que la actividad eléctrica de un cultivo neuronal biológico controle el comportamiento del agente artificial (Potter, 2001).

La hipótesis que subyace a esta metodología es que la capacidad de aprendizaje y adaptación de los organismos a condiciones ambientales cambiantes es el resultado de la interacción continua del sistema nervioso con el entorno, mediada por el cuerpo (Novellino et al., 2007). Es decir, los sistemas neuronales han evolucionado para servir a un cuerpo que está en interacción constante con el ambiente; los sistemas neuronales son *corporizados* y están *situados* (Potter, 2001).

Debido a que la interacción con el ambiente influye en la formación de conexiones cerebrales, el alcance explicativo de los modelos *in vitro* utilizados para estudiar los mecanismos neuronales que subyacen al aprendizaje está severamente limitado. La metodología de los cultivos neuronales embebidos aparece como una alternativa al estudio del sistema nervioso de manera aislada (Potter, 2001).

La Fig. 3.1 ilustra el esquema de un experimento realizado con cultivos neuronales embebidos. DeMarse et al. (2001) lograron controlar la navegación de un animal artificial simulado, denominado *Animat*, en un entorno con obstáculos y paredes. El movimiento del agente artificial es modulado mediante una red neuronal de cientos de miles de neuronas corticales de mamífero cultivadas *in vitro*. La actividad eléctrica del cultivo es registrada y se utiliza para controlar el comportamiento del *Animat*, mientras que la entrada sensorial del cultivo la proporciona el ordenador en forma de actividad eléctrica, simulando de esta manera un ciclo sensorimotor (DeMarse et al., 2001).

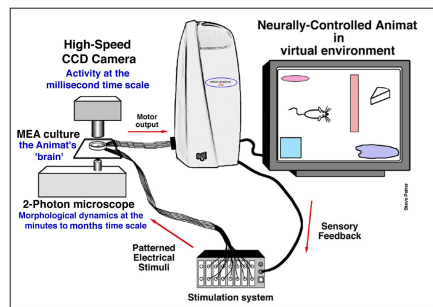


Figura 3.1: Agente virtual controlado neuronalmente (DeMarse et al., 2001).

Los instrumentos de uso tradicional en la Neurociencia, como el electrodo de micropipeta de vidrio, no permiten estudiar las propiedades globales de los cultivos neuronales. Es por ello que la innovación y el desarrollo de nuevas técnicas de registro de actividad neuronal fueron necesarios para el surgimiento de la metodología de los cultivos neuronales embebidos (Potter, 2001).

3.1. Arreglo de Multi-Electrodos

En la actualidad, el estudio de las propiedades dinámicas de las redes neuronales biológicas puede llevarse a cabo mediante un dispositivo denominado arreglo de Multi-electrodos (MEA, por sus siglas en inglés *Multi-electrode array*). Este instrumento está conformado por una matriz de microelectrodos

que son del tamaño de las células aproximadamente ($10\text{-}100\ \mu\text{m}$). Generalmente, los microelectrodos se encuentran formando una matriz o arreglo de 8×8 (Fig. 3.2b). El arreglo de microelectrodos es colocado en el fondo de una caja de cultivo celular o caja de Petri (Fig. 3.2a). La disposición de los electrodos permite obtener el registro de actividad eléctrica de diferentes zonas del cultivo celular en un mismo instante. Asimismo, cada electrodo es capaz de registrar la suma de la actividad eléctrica de las neuronas asociadas a él (Fig. 3.2c). Además de registrar actividad eléctrica, los microelectrodos también permiten estimular a las células mediante pulsos de corriente o voltaje. El sistema de electrodos está conectado a dispositivos electrónicos externos capaces de registrar las señales eléctricas generadas y estimular eléctricamente al cultivo (Potter, 2001).




Figura 3.2: a) Caja de Petri que conforma al MEA, b) Arreglo de electrodos en el centro del MEA, c) Acercamiento a un electrodo que está en contacto con varias neuronas interconectadas entre sí (Xydas et al., 2008).

En contraste con la micropipeta de vidrio, el MEA permite realizar el registro y estimulación de manera extracelular, por lo que las células no sufren daño durante los registros experimentales. Esta característica hace posible una conexión más duradera entre la red neuronal y una computadora, lo que resulta útil para el estudio de patrones de actividad eléctrica por periodos de tiempo relativamente largos. Los MEA fueron descritos por primera vez en 1972; no obstante, sólo hasta finales de la década de 1990 se empezaron a utilizar para controlar agentes artificiales (Potter, 2001).

A pesar de que los cultivos neuronales embebidos han generado un creciente interés dentro de la comunidad científica, esta tecnología sigue en desarrollo debido a las complicaciones experimentales inherentes a la manipulación de neuronas biológicas *in vitro*. Una de las limitaciones de esta metodología está relacionada con el tiempo de preservación de los cultivos neuronales *in vitro*, ya que la contaminación a la que se exponen los cultivos durante la realización de los experimentos es un factor limitante para el estudio de la dinámica neuronal durante periodos de tiempo relativamente largos (Potter and DeMarse, 2001).

Por otro lado, se ha mencionado que esta metodología permitiría estudiar procesos cognitivos como el aprendizaje y la memoria (Potter, 2001). Sin embargo, las conclusiones preliminares de los experimentos realizados con agentes controlados neuronalmente son reservadas en este aspecto. En la actualidad, las investigaciones llevadas a cabo con sistemas híbridos únicamente permiten afirmar que es posible obtener una estabilización de patrones de activación, donde es más probable obtener algunos patrones neuronales que otros. No obstante, no se ha podido entender qué papel juega el entorno en estos patrones generados y cuáles son producto de la manipulación del experimentador. Además, no se ha logrado que los agentes controlados neuronalmente se adapten únicamente a partir de su interacción con el entorno. En otras palabras, las aspiraciones cognitivas de la metodología de los cultivos neuronales embebidos aún no han sido cumplidas (Manson, 2004).

3.2. Neurociencia e Inteligencia artificial

Las Ciencias cognitivas en general, como la Psicología y la Robótica cognitiva, están siendo inspiradas cada vez más por mecanismos biológicos. Esto es provocado en cierta medida por el gran avance generado dentro de la Neurociencia experimental durante las últimas décadas. No obstante, así como la

Neurociencia puede generar conocimiento útil para las demás subdisciplinas de las Ciencias cognitivas, ella misma puede recibir retroalimentación de diversas áreas, como de la Inteligencia Artificial. La metodología de los cultivos neuronales embebidos es una muestra de la interacción de la Neurociencia con la Robótica en busca de nuevas fronteras y nuevas formas de explicar diversos fenómenos. Sin embargo, este enfoque aún presenta diversas limitaciones técnicas. Es por ello que se considera oportuno el método de las simulaciones y el enfoque de las redes neuronales artificiales bioinspiradas y embebidas para retroalimentar a la Neurociencia experimental y fomentar el desarrollo de la metodología de los cultivos neuronales embebidos. La estrecha relación entre la Neurociencia computacional, la Robótica Cognitiva y la Neurociencia experimental puede impulsar paradigmas experimentales como el de los cultivos neuronales embebidos (Potter, 2007).

3.3. Simulaciones de cultivos neuronales

Algunas investigaciones realizadas dentro de la Neurociencia computacional se enfocan en la simulación de cultivos neuronales. Una herramienta útil para estos estudios son los diversos modelos de redes neuronales artificiales de potenciales de acción (estos modelos serán descritos en el siguiente capítulo). Las simulaciones pueden ser de cultivos neuronales aislados o embebidos, ya que los cultivos neuronales simulados pueden, o no, estar acoplados a un agente artificial.

Los estudios realizados con simulaciones de cultivos aislados tienen la finalidad de explorar la autoorganización de grupos celulares dentro de redes complejas de neuronas. Un ejemplo de ello es el trabajo de Izhikevich et al. (2004), en el cual se reportan los resultados de una simulación de un cultivo conformado por 100 000 neuronas interconectadas entre sí, cuya arquitectura está inspirada en la anatomía de la corteza cerebral. Sin embargo, el trabajo únicamente está orientado hacia la búsqueda de patrones de activación del cultivo aislado.

Por otro lado, existen implementaciones de redes neuronales artificiales de potenciales de acción para el control de agentes artificiales. Algunas de ellas sólo describen una arquitectura de red neuronal capaz de controlar la navegación de un agente artificial embebido en un entorno, sin generar un proceso de aprendizaje en el sistema. Tal es el caso del trabajo reportado por Mokhtar et al. (2007), el cual se enfoca en el diseño de un hardware de un

modelo de neurocontrolador basado en redes neuronales artificiales cuyas conexiones están inspiradas en las redes de neuronas piramidales del hipocampo. Este trabajo hace énfasis en el hipocampo debido a que dicha estructura ha sido considerada como responsable de la navegación en mamíferos.

Finalmente, también existen investigaciones que implementan redes neuronales artificiales para estudiar aprendizaje autónomo en agentes artificiales. Aunque este tipo de proyectos son los menos abundantes en la literatura, los modelos de redes neuronales de potenciales de acción han impulsado el desarrollo de este campo de estudio. Trhan (2012) reporta algunos experimentos de control de un agente *Legó Mind-storms NXT* mediante el uso de redes neuronales de potenciales de acción. La arquitectura que propone consta de dos redes neuronales locales que procesan la información sensorial del agente en forma paralela, una controla el lado derecho del agente y la otra el izquierdo. En dicho trabajo se reporta que la red neuronal aprende a controlar los movimientos del agente con base en la interacción con el entorno. El sistema se adapta al entorno a través del desarrollo evolutivo de una población de individuos. El mecanismo de evolución implementado permite la adaptación de la red neuronal en un periodo de tiempo corto y la red es capaz de controlar el agente artificial de tal forma que éste no choque con las paredes del entorno.

Redes neuronales artificiales de potenciales de acción

4.1. Redes Neuronales Artificiales bioinspiradas

Las Redes Neuronales Artificiales (ANN, por sus siglas en inglés *Artificial Neural Networks*) son modelos que están inspirados en la arquitectura y funcionamiento del sistema nervioso. Estas redes están conformadas por elementos denominados unidades o neuronas. Cada unidad es un procesador que recibe señales de entrada de otras unidades a las que se encuentra interconectada. Las señales de entrada son transformadas en una única salida basándose en una función matemática. Esta salida es propagada por la ANN dependiendo del patrón de conexión global de la red.

Las ANN han sido clasificadas en tres generaciones con base en el modelo matemático de sus unidades o neuronas. La primera generación está basada en el modelo de neurona de McCulloch-Pitts. El rasgo característico de este modelo de redes es que sus neuronas únicamente generan salidas digitales (por ejemplo, 0 o 1). Por otro lado, las unidades de las ANN de segunda generación generan un set continuo de valores de salida (entre 0 y 1) mediante la aplicación de una función de activación, que comúnmente es una función sigmoide. En contraste, la tercera generación de ANN emplea unidades o neuronas de potenciales de acción. Los modelos de neurona de las ANN de tercera generación describen de manera más realista la salida de una neurona biológica, ya que capturan la naturaleza de impulsos eléctricos o potenciales de acción de estas células. Una de las ventajas de las neuronas de potenciales de acción es que permiten usar el tiempo como un recurso en el procesamiento de información, ya que la salida de una neurona de este tipo es el cambio de potencial de membrana con respecto al tiempo (Maass, 1997).

Existen diversos modelos de neurona de potenciales de acción. El cuadro de la Fig. 4.1 muestra algunos de estos modelos e indica el tipo de comportamientos neuronales que son capaces de reproducir, así como el número de operaciones de punto flotante (suma, resta, multiplicación, etc.) que se requieren para simular cada modelo durante 1 ms.

Models	biophysically meaningful	tonic spiking	phasic spiking	tonic bursting	phasic bursting	mixed mode	spike frequency adaptation	class 1 excitable	class 2 excitable	spike latency	subthreshold oscillations	resonator	integrator	rebound spike	rebound burst	threshold variability	biadaptability	DAP	accommodation	inhibition-induced spiking	inhibition-induced bursting	chaos	# of FLOPS
integrate-and-fire	-	+	-	-	-	-	+	-	-	-	-	+	-	-	-	-	-	-	-	-	-	-	5
integrate-and-fire with adapt.	-	+	-	-	-	+	+	-	-	-	-	+	-	-	-	-	+	-	-	-	-	-	10
integrate-and-fire-or-burst	-	+	+		+	-	+	+	-	-	-	+	+	+	-	+	+	-	-	-	-	-	13
resonate-and-fire	-	+	+	-	-	-	+	+	-	+	+	+	+	+	-	-	+	+	+	-	-	+	10
quadratic integrate-and-fire	-	+	-	-	-	-	+	-	+	-	-	+	-	-	+	+	-	-	-	-	-	-	7
Izhikevich (2003)	-	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	13
FitzHugh-Nagumo	-	+	+	-		-	+	-	+	+	+	-	+	-	+	+	-	+	+	-	-	-	72
Hindmarsh-Rose	-	+	+	+			+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	120
Morris-Lecar	+	+	+	-		-	+	+	+	+	+	+	+	+	+	+	-	+	+	-	-	-	600
Wilson	-	+	+	+			+	+	+	+	+	+	+	+	+	+	+	+					180
Hodgkin-Huxley	+	+	+	+			+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	1200

Figura 4.1: Modelos de neurona de potenciales de acción. Comparación de las propiedades neuro-computacionales de modelos de potenciales de acción. # of FLOPS es un número aproximado de las operaciones de punto flotante (suma, multiplicación, etc.) que se requieren para simular el modelo durante un lapso de tiempo de 1 ms. Cada cuadro vacío indica la propiedad que el modelo debería exhibir en principio, si los parámetros son elegidos apropiadamente, pero que el autor falló en encontrar los parámetros en un período de tiempo razonable (Izhikevich, 2004).

Al realizar simulaciones numéricas de redes neuronales artificiales que implementen modelos de neurona de potenciales de acción se debe asumir un compromiso entre dos requisitos que parecen ser mutuamente excluyentes. Por

un lado, el modelo de neurona debe ser computacionalmente simple, aunque por otro lado, debe ser capaz de reproducir los diversos patrones de disparo de las neuronas biológicas. Los modelos biofísicamente precisos, como el modelo de Hodgkin–Huxley, resultan computacionalmente costosos. Debido a la cantidad de operaciones de números flotantes que implementan, sólo es posible simular un número limitado de neuronas en tiempo real con este tipo de modelos. En contraste, modelos del tipo integrate-and-fire resultan computacionalmente eficientes. Sin embargo, estos modelos son poco realistas e incapaces de reproducir la dinámica de potenciales de acción registrada experimentalmente en neuronas biológicas (Izhikevich et al., 2003).

Uno de los modelos de neurona de potenciales de acción más simples fue propuesto por Izhikevich et al. (2003). Este modelo es tan biológicamente plausible como el modelo de Hodgkin–Huxley y computacionalmente eficiente como el modelo de integrate-and-fire (Izhikevich et al., 2003).

4.2. Modelo de neurona de Izhikevich

El modelo simple de neurona de potenciales de acción de Izhikevich et al. (2003) es capaz de reproducir potenciales de acción de diferentes tipos de neuronas biológicas corticales únicamente a partir de cuatro parámetros. Este modelo consta de un sistema de ecuaciones diferenciales ordinarias de dos dimensiones, de la forma:

$$v' = 0.04v^2 + 5v + 140 - u + I \quad (4.1)$$

$$u' = a(bv - u) \quad (4.2)$$

Con una condición de reajuste:

$$\text{Si } v \geq 30, \text{ entonces } \begin{cases} v \leftarrow c \\ u \leftarrow u + d \end{cases} \quad (4.3)$$

donde v representa el potencial de membrana de la neurona y u es una variable de recuperación de la membrana, la cual proporciona una retroalimentación negativa a la variable v . La variable I corresponde a la corriente de entrada. Los parámetros del modelo son a , b , c y d . Los valores asignados a cada uno de ellos permiten reproducir diferentes comportamientos neuronales (Fig. 4.2).

El efecto que cada parámetro posee sobre la dinámica neuronal se detalla a continuación:

- a : describe la escala de tiempo de recuperación de la variable u . Valores pequeños resultan en una recuperación más lenta.
- b : describe la sensibilidad de la variable u a las fluctuaciones subumbrales del potencial de membrana v . Valores grandes acoplan fuertemente a u y v , resultando en posibles oscilaciones subumbrales y dinámica de potenciales de acción con un umbral bajo.
- c : describe el valor de reajuste del potencial de membrana v después de un potencial de acción.
- d : describe el valor de reajuste de la variable de recuperación u después de un potencial de acción.

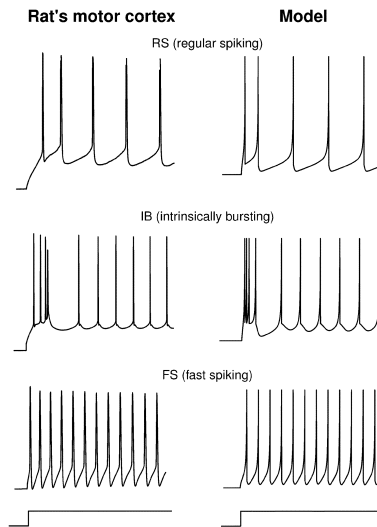


Figura 4.2: Diferentes comportamientos neuronales. El modelo simple de neurona puede reproducir patrones de disparo registrados en neuronas de corteza motora de rata (Izhikevich et al., 2003).

Los valores sugeridos por Izhikevich et al. (2003) para reproducir el comportamiento de neuronas excitatorias e inhibitorias son:

- Neurona excitatoria: $a = 0.02$, $b = 0.2$, $c = -65.0$, $d = 8.0$
- Neurona inhibitoria: $a = 0.1$, $b = 0.2$, $c = -65.0$, $d = 2.0$

El modelo simple de neurona de potenciales de acción de Izhikevich et al. (2003) ha generado un creciente interés en la Neurociencia computacional debido a su plausibilidad biológica y eficiencia computacional. Sin embargo, hay pocas investigaciones que implementen este modelo para el control motor de agentes artificiales dentro de la Robótica cognitiva. Asimismo, existe escasa literatura acerca de algoritmos de aprendizaje autónomo para redes neuronales artificiales *embebidas* conformadas por este tipo de modelo de neurona.

4.3. Redes neuronales artificiales embebidas

Scheier et al. (1998) reportó un experimento realizado con redes neuronales artificiales utilizadas para el control de un agente autónomo que debe aprender a moverse por un entorno evadiendo obstáculos. En dicha investigación no se utilizan modelos de neurona de potenciales de acción. Sin embargo, la estrategia de aprendizaje implementada en ese trabajo se describe a continuación debido a que los sistemas diseñados para el proyecto de la presente tesis están inspirados en este experimento.

El agente que utiliza Scheier et al. (1998) durante los experimentos posee sonares infrarrojo, dos motores (con llantas) y dos sensores para medir la velocidad de las llantas. Los sensores infrarrojo son utilizados como sensores de proximidad. Entre más cercano se encuentre el agente de los obstáculos, mayor activación presentarán los sensores. Estos mismos sensores infrarrojo son utilizados como sensores de colisión, de tal forma que cada vez que los sonares se saturan se considera que ha ocurrido una colisión (Scheier et al., 1998).

Las llantas del agente son independientes una de la otra y las conductas observadas dependen de la diferencia de las velocidades entre ellas. Si las dos llantas avanzan a la misma velocidad, el robot se mueve hacia adelante; si la llanta derecha se detiene y únicamente la llanta izquierda avanza, entonces el robot gira a la derecha y, viceversa. Además, el agente tiene unos reflejos incorporados: si el sensor de colisión del lado derecho se activa, el agente retrocederá un poco y girará a la izquierda y, viceversa. Si no hay obstáculos

cerca de él, entonces se moverá hacia adelante. (Scheier et al., 1998).

La arquitectura neuronal que proponen presenta tres capas de neuronas: una capa de colisión, una capa de proximidad y una capa motora (Fig. 4.3). Cada sensor está conectado a una neurona de la red: los sensores de colisión están conectados a la capa de colisión y los sensores de proximidad a la capa de proximidad. Los nodos de colisión tienen un umbral binario, mientras que los nodos de proximidad presentan una función de activación continua de tipo sigmoide y su valor depende del grado de activación de los sensores (Scheier et al., 1998).




Figura 4.3: Red Neuronal acoplada con el robot. Los sensores de proximidad se muestran en negro y los sensores de colisión en gris. La capa de proximidad de la red neuronal está completamente conectada con la capa de colisión mediante conexiones modificables. La modificación de las conexiones se realiza mediante la implementación de un cierto tipo de aprendizaje Hebbiano (Scheier et al., 1998).

La capa de proximidad está completamente conectada con la capa de colisión en una dirección (*feedforward*). La fuerza de estas conexiones es modificable y sus valores cambian con base en una regla de aprendizaje Hebbiano (la regla de Hebb se detallará más adelante). Los nodos de la capa de colisión están conectados a la capa de salida motora mediante conexiones fijas. Estas conexiones son las responsables de los reflejos incorporados del agente (Scheier et al., 1998).

Cuando el robot choca con un obstáculo, se activa el nodo de colisión correspondiente. Simultáneamente, se activan los nodos de proximidad conectados con los sensores que se encuentran cercanos al obstáculo. Las conexiones entre

los nodos de colisión y de proximidad que se activan al mismo tiempo se refuerzan. Si el agente choca varias veces con un obstáculo del lado derecho, el nodo de colisión y de proximidad correspondientes se activarán varias veces. Esto originará que se refuerce siempre la misma conexión. En algún momento, la activación originada en la capa de proximidad será lo suficientemente fuerte para conseguir que la capa de colisión se active sin necesidad de que haya una colisión. Cuando esto ocurre, se considera que el robot ha aprendido a evadir obstáculos (Scheier et al., 1998).

Formalización de la regla de Hebb

Como se ha mencionado anteriormente (sección 2.3), Hebb postuló el primer enunciado de aprendizaje a nivel neuronal. La idea de Hebb ha sido resumida en la siguiente frase: si dos neuronas disparan simultáneamente, la conexión entre ellas se refuerza. La ecuación general de la regla de Hebb es:

$$\Delta w = \eta \text{act}(n_{pre}) \cdot \text{act}(n_{post}) \quad (4.4)$$

donde Δw es el cambio en el peso sináptico entre la neurona presináptica y la neurona postsináptica, η es la tasa de aprendizaje, $\text{act}(n_{pre})$ corresponde al grado de activación de la neurona presináptica y $\text{act}(n_{post})$ indica la activación de la neurona postsináptica. El postulado de Hebb se enfoca únicamente en el aprendizaje. No obstante, actualmente existen modificaciones a la regla de aprendizaje que consideran una tasa de olvido.

Diseño de agentes reactivos

En este capítulo se muestra una forma de implementar algunas de las herramientas computacionales bioinspiradas descritas en el capítulo anterior. El objetivo es conseguir que un agente artificial acoplado a una red neuronal artificial de potenciales de acción presente un comportamiento reactivo de evasión de obstáculos. Los agentes reactivos se diseñaron como un primer acercamiento al modelo de neurona de Izhikevich et al. (2003). Es importante mencionar que estos sistemas no cuentan con un proceso de aprendizaje, ya que la finalidad principal de estos experimentos fue la exploración de los parámetros que controlan el comportamiento de las neuronas. A continuación se describen las características del agente artificial utilizado, así como los parámetros implementados durante las simulaciones.

5.1. Agente artificial

Durante los experimentos se utilizó un agente artificial simulado denominado Pioneer 3DX, que es uno de los robots móviles más empleados para investigación académica. El agente presenta un anillo de ocho sensores ultrasónicos (sonares) y dos motores (con ruedas) a cada lado (Fig. 5.1). La plataforma de Pioneer incluye la librería de C++ *Advanced Robotics Interface for Application* (ARIA), la cual permite controlar la velocidad y movimientos del agente.

El agente y su entorno fueron simulados con MobileSim, un software libre utilizado para simular plataformas de robots móviles y sus entornos. MobileSim obtiene la información del entorno de un archivo denominado MobileRobots map para simular paredes y otros obstáculos en el entorno artificial. El entorno diseñado para los experimentos presenta obstáculos cuadrados con una separación de 400 mm entre cada uno de ellos (Fig.5.2).




Figura 5.1: Agente artificial Pioneer 3DX




Figura 5.2: Muestra del entorno simulado durante los experimentos.

5.2. Modelo de Neurona

El modelo de neurona implementado durante los experimentos fue el modelo simple de neurona de potenciales de acción propuesto por Izhikevich et al. (2003) (sección 4.2). Los valores asignados a los parámetros del modelo durante la simulación fueron los reportados por el autor para reproducir la dinámica de neuronas excitatorias denominadas *Regular Spiking* (Tabla 5.1). Este tipo de neuronas son las más abundantes de la corteza cerebral de mamíferos. Su dinámica se caracteriza por exhibir un fenómeno de adaptación de frecuencia de disparos cuando son estimuladas de manera prolongada. Es decir, la frecuencia de potenciales de acción de estas neuronas disminuye a través del tiempo a pesar de que el estímulo persista. Otra característica de este tipo

de neuronas es que su frecuencia de disparo aumenta cuando la corriente que reciben se incrementa, aunque nunca disparan demasiado rápido debido a la fase larga de hiperpolarización que presentan. En el modelo, lo anterior corresponde a un valor más negativo del voltaje de reajuste ($c=-65.0$) y a un valor alto del reajuste de la variable de recuperación u ($d=8.0$).

Parámetro	a	b	c	d
Valor	0.02	0.2	-65.0	8.0

Cuadro 5.1: Parámetros para simular neuronas excitatorias

Los valores iniciales del potencial de membrana y de la variable de recuperación para cada neurona fueron $v_o=-65.0$ y $u_o=-13.0$, respectivamente. Estos valores fueron establecidos tomando como referencia el experimento reportado en Izhikevich et al. (2003). El potencial de membrana en reposo fue establecido en -65.0 o -70.0 mV, dependiendo del tipo de neurona (sensorial, interneurona o motora) dentro de la arquitectura de la red. Esto corresponde a una corriente I_{base} de entrada de 0 o 3.5, respectivamente.

5.3. Agentes reactivos

Los sistemas artificiales que presentan un comportamiento reactivo de evasión de obstáculos están conformados por una red neuronal artificial de potenciales de acción acoplada al agente simulado (Fig. 5.3).




Figura 5.3: Sistemas reactivos capaces de evadir obstáculos.

Los dos sistemas presentan una red neuronal con ocho neuronas sensoriales y dos neuronas motoras, que se ilustran con círculos azules y verdes, respectivamente. Sin embargo, una de ellas presenta dos interneuronas adicionales, mostradas en rosa (Fig. 5.3(a)). En ambos sistemas las neuronas sensoriales están asociadas a un sensor del agente artificial, de tal manera que, el sensor 1 está asociado a la neurona sensorial 1, el sensor 2 a la neurona sensorial 2 y así sucesivamente. A su vez, las neuronas sensoriales están conectadas a las interneuronas o a las neuronas motoras, dependiendo del sistema.

En la Arquitectura 1 (Fig 5.3(a)), las neuronas sensoriales 1, 2, 3 y 4, que corresponden al lado izquierdo del agente, están conectadas a la interneurona 1. Por otro lado, las neuronas 5, 6, 7 y 8 se conectan a la interneurona 2. En este sistema, cada interneurona se conecta a la neurona motora que se encuentra del mismo lado de la arquitectura.

En el caso de la Arquitectura 2 (Fig 5.3(b)), las neuronas sensoriales están conectadas directamente a las neuronas motoras. Las neuronas sensoriales 1, 2, 3 y 4 están conectadas con la neurona motora 1, mientras que las neuronas sensoriales del lado derecho se conectan con la neurona motora 2.

Asimismo, cada neurona motora está asociada a un motor en ambos sistemas. La neurona motora 1 está asociada al motor izquierdo, mientras que la neurona motora 2 se asocia con el motor del lado derecho del agente. Con respecto a las ruedas del agente, cada una de ellas es independiente de la otra. Por lo tanto, si la rueda izquierda acelera y la rueda derecha mantiene su velocidad constante, el agente girará hacia la derecha y, viceversa. Durante los experimentos, se estableció una velocidad base para los motores, del tal manera que cuando no hay un obstáculo cerca del agente, ambas ruedas mantienen la misma velocidad y el agente avanza en línea recta.

Transmisión de la información en los sistemas reactivos

El procesamiento y transmisión de la información en los sistemas reactivos puede dividirse en las fases que se indican a continuación y que se resumen en la Fig. 5.4:

- **Normalización del registro de los sonares:** Originalmente, cada uno de los ocho sonares del agente puede registrar obstáculos que se encuentren dentro de un intervalo de distancia entre 0 (cerca) y 5000 mm (lejos). Estos valores fueron normalizados en un intervalo de 0 a 1, de tal forma que el valor máximo indica proximidad máxima con el

obstáculo. Se utilizó la ecuación 5.1 para llevar a cabo la normalización del registro de los sonares.

$$s_n = 1 - \frac{s}{5000} \quad (5.1)$$

donde s es el valor original del sonar y s_n es el valor normalizado.

- **Traducción de información de sonares a neuronas sensoriales:** La información de los sonares fue traducida a una corriente de entrada para las neuronas sensoriales de las redes. Esta corriente de entrada es proporcional al grado de activación de los sensores. Por lo tanto, la frecuencia de disparo de las neuronas sensoriales es mayor en presencia de obstáculos.
- **Propagación de la información:** Este proceso depende del patrón de conexiones de cada una de las redes, así como del valor de la fuerza de conexión o peso sináptico entre las neuronas. Si la fuerza de conexión es alta, la corriente con la que contribuye la neurona presináptica a la neurona postsináptica será suficiente para desencadenar un potencial de acción en ella. De lo contrario, la corriente de contribución no desencadenará un potencial de acción en la neurona postsináptica.
- **Traducción de actividad de neuronas motoras en velocidades de los motores:** La velocidad de los motores se asignó dependiendo de la tasa de potenciales de acción de las neuronas motoras registrada en una ventana de tiempo determinada. Se realizaron pruebas con ventanas de tiempo de diferente duración para elegir una ventana de tiempo adecuada. Se eligió una ventana de tiempo de 400 ms debido a que las ventanas de tiempo de menor duración podían registrar muy pocos potenciales de acción, mientras que ventanas de tiempo muy largas requerían de simulaciones de mayor duración o de tasas de aprendizaje mayores. Para calcular la velocidad de los motores se utilizó la siguiente ecuación:

$$V_{motor} = 350 \cdot \frac{PA}{PA_{max}} + 150 \quad (5.2)$$

donde V_{motor} es la velocidad asignada al motor, PA es el número de potenciales de acción dentro de la ventana de tiempo establecida y PA_{max}

el número máximo de potenciales de acción que puede generarse en la ventana de tiempo. Esta velocidad será asignada al motor izquierdo si los potenciales de acción corresponden a la neurona motora izquierda, y al motor derecho si la neurona motora derecha es la que dispara. Si PA es cero, entonces se asigna una velocidad base a los motores, que en la ecuación corresponde a 150 mm/s.

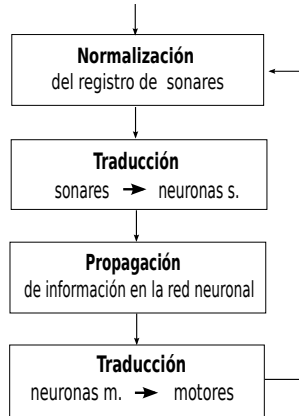


Figura 5.4: Transmisión de la información en los sistemas reactivos.

5.3.1. Evasión de dos obstáculos

En esta sección se muestran los resultados de un experimento realizado con el sistema artificial que presenta ocho neuronas sensoriales, dos interneuronas y dos neuronas motoras (Fig. 5.3(a)). En este experimento se estableció un valor de 0.7 para cada uno de los pesos sinápticos entre las neuronas, valor que permanece fijo durante toda la simulación. Un valor de 0.7 es suficiente para asegurar que cada vez que una neurona dispare, las neuronas conectadas a ella también disparen. Durante el experimento el agente artificial debe evadir dos obstáculos que se encuentran cercanos a él.

El recorrido realizado por el agente artificial durante la simulación se muestra en la Fig. 5.5. El agente detecta el obstáculo que está frente a él en el instante **a** y gira. Posteriormente, detecta un segundo obstáculo durante el

instante **b**. El registro de los sonares y la activación de las neuronas sensoriales correspondientes durante la evasión de los obstáculos se muestran en las Figs. 5.6 y 5.7. La Fig. 5.6(a) muestra la activación de los sonares 1, 2, 3 y 4, los cuales se localizan del lado izquierdo de la arquitectura del agente. A su vez, el registro de la actividad de las neuronas sensoriales asociadas a cada uno de estos sonares se presenta en la Fig. 5.6(b). Las gráficas muestran que el primer sensor que se activa durante el instante **a** es el sensor 3, alrededor del ms 3000. Su activación desencadena una serie de potenciales de acción en la neurona sensorial 3, información que se transmite a la interneurona 1 y, posteriormente, a la neurona motora 1 (Fig. 5.8). Los potenciales de acción generados por la neurona motora 1 provocan que el motor del lado izquierdo incremente su velocidad, por lo que el agente gira hacia la derecha para evadir el obstáculo. Durante el giro del agente, el mismo obstáculo es detectado por los sensores 2 y 1 (poco tiempo después del ms 4000 y 6000, respectivamente), lo que genera potenciales de acción en las neuronas sensoriales asociadas a estos sensores. Esta información también se transmite hasta las neuronas motoras e influye en la velocidad del giro del agente.





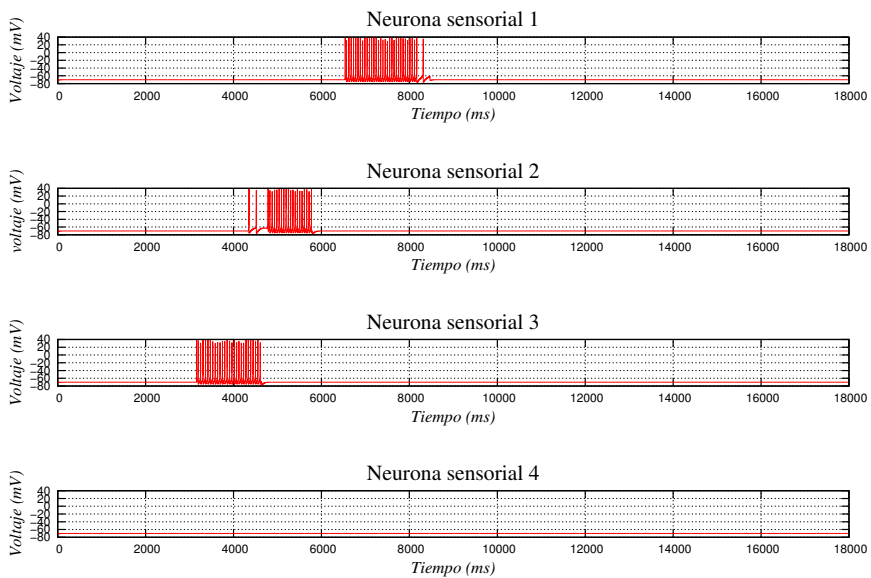
Figura 5.5: Evasión de dos obstáculos. La letra **a** indica un instante en el que el agente artificial detecta uno de los obstáculos y gira para evitarlo. Al girar, el agente detecta un segundo obstáculo en el instante **b**.

En el instante **b**, el sensor 8 del lado derecho de la arquitectura se activa a partir del ms 6000 debido al segundo obstáculo (Fig. 5.7(a)), desencadenando la activación de la neurona sensorial 8 (Fig. 5.7(b)), así como a la interneurona 2 y neurona motora 2, subsecuentemente (Fig. 5.8). Esto tiene como resultado

un incremento en la velocidad del motor derecho, que reajusta la dirección del agente. Los cambios en las velocidades del agente, asociados a la transmisión de información desde los sonares hasta las neuronas motoras, resultan en la evasión exitosa de ambos obstáculos. Finalmente, los sensores no detectan algún obstáculo cercano, por lo que las neuronas no disparan y las velocidades de ambos motores vuelven a su velocidad base. Esto genera que el agente avance hacia adelante nuevamente.

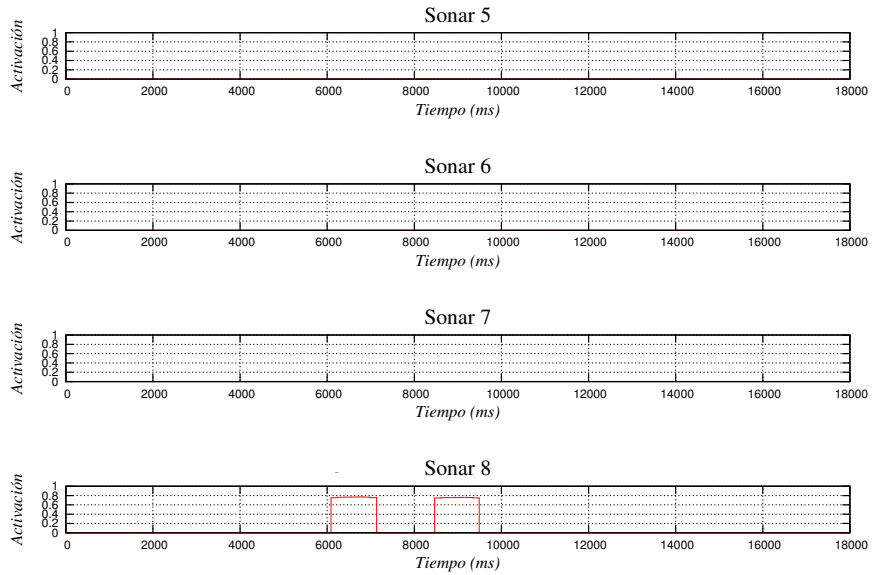


(a)

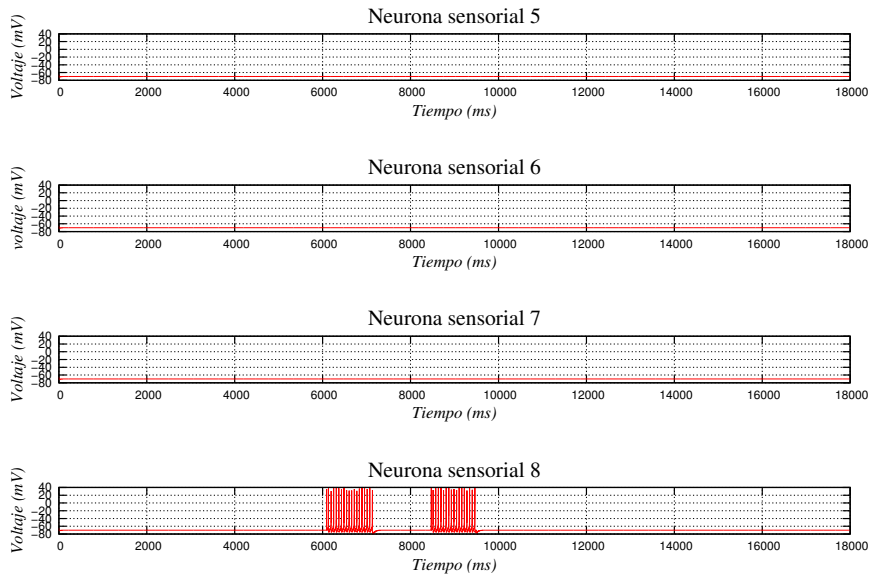


(b)

Figura 5.6: Registro de sonares y neuronas sensoriales del lado izquierdo.



(a)



(b)

Figura 5.7: Registro de sonares y neuronas sensoriales del lado derecho.

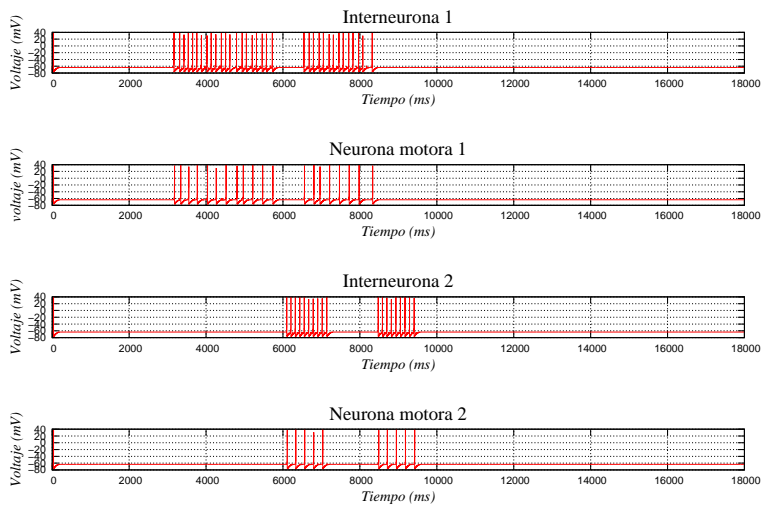


Figura 5.8: Registro de la actividad de las interneuronas y neuronas motoras.

5.3.2. Evasión y giro

El experimento que se presenta en esta subsección se realizó con la arquitectura 2, la cual presenta únicamente ocho neuronas sensoriales y dos neuronas motoras (Fig. 5.3(b)). El peso sináptico establecido entre las conexiones de la red fueron fijadas en un valor de 0.7, como en el experimento descrito previamente. El comportamiento del agente artificial durante la simulación se muestra en la Fig. 5.9.




Figura 5.9: El agente artificial detecta una barrera de obstáculos en su trayectoria y da medio giro para evitarlos.

El agente artificial detecta una barrera de obstáculos con los sensores y neuronas que se encuentran del lado izquierdo de su arquitectura. La Fig. 5.10 muestra que los sensores 1, 2, 3 y 4 mantienen una activación alta durante la primera parte del tiempo de simulación. Por lo tanto, las neuronas asociadas a dichos sensores generan potenciales de acción, disminuyendo su tasa de disparo con el tiempo. A su vez, el resultado de estas activaciones se ve reflejado en la actividad de la neurona motora 1 (Fig. 5.12), generando un incremento en la velocidad de la rueda izquierda. Después de girar, la actividad de los sensores y neuronas del lado derecho de la arquitectura se incrementa debido a la detección de un obstáculo que se localiza del lado derecho del entorno. Esto sucede un poco después del ms 3000, como se ilustra en la Fig. 5.11. Finalmente, la neurona sensorial 1 y la neurona motora 1 se activan nuevamente a partir del ms 6000, generando nuevamente un cambio en las velocidades del agente.

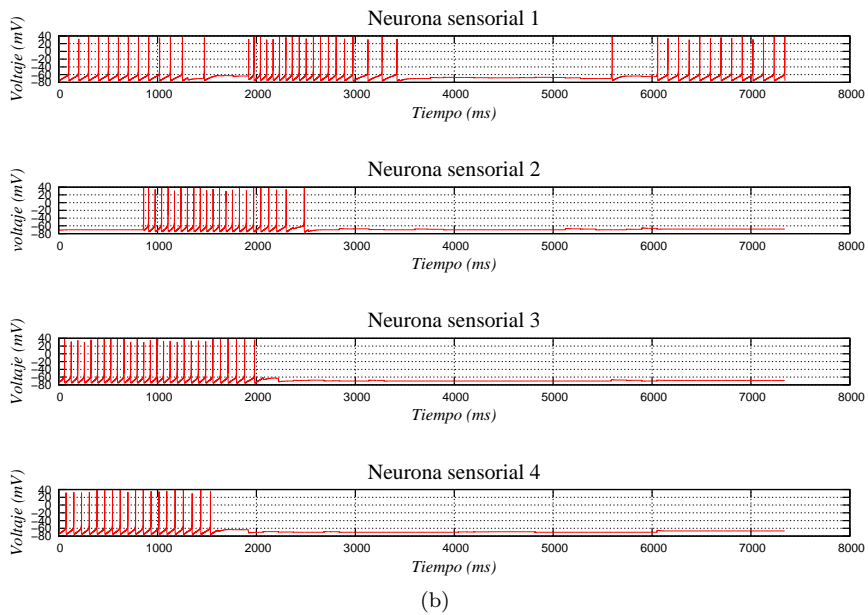
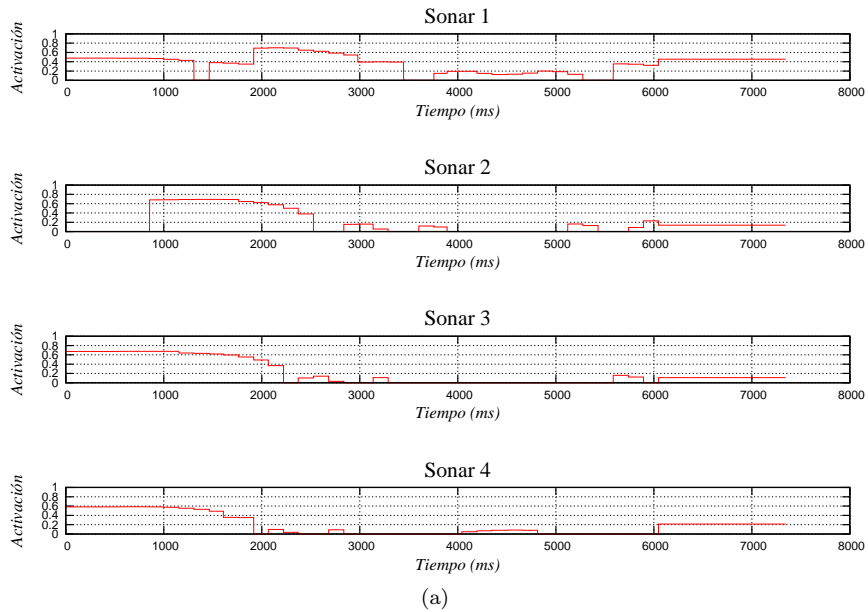


Figura 5.10: Actividad de sonares y neuronas sensoriales del lado izquierdo.

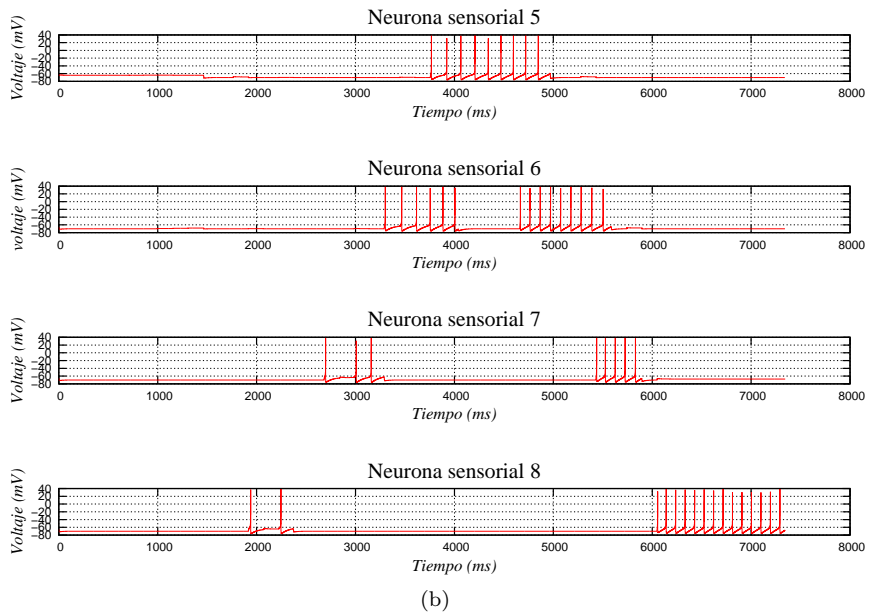
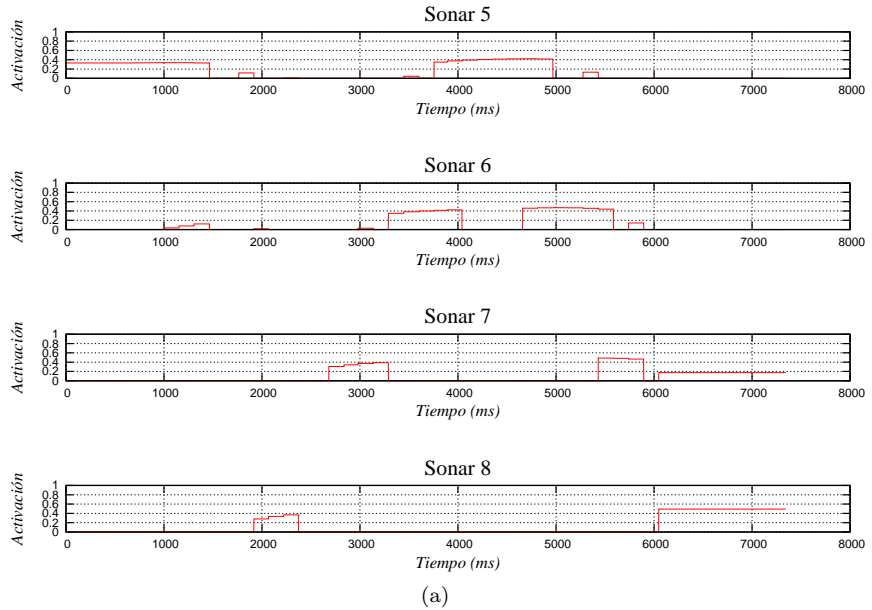


Figura 5.11: Actividad de sonares y neuronas sensoriales del lado derecho.

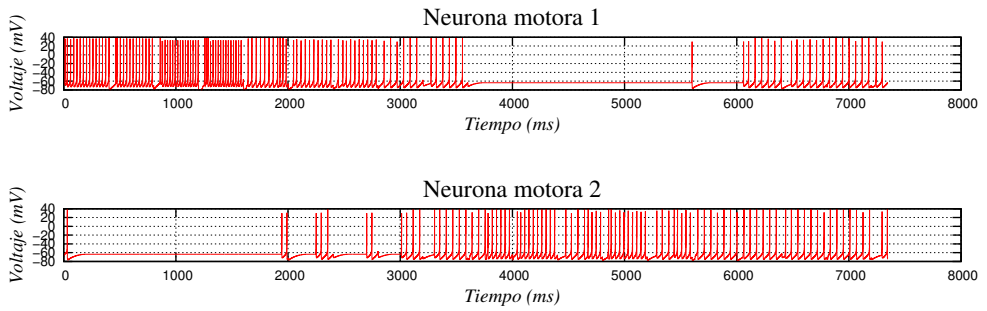


Figura 5.12: Actividad de las neuronas motoras.

Aprendizaje autónomo de evasión de obstáculos

En este capítulo se muestran los resultados obtenidos con dos sistemas (Fig. 6.1) diseñados para llevar a cabo el proceso de aprendizaje durante una tarea de evasión de obstáculos. Las redes neuronales que componen a estas arquitecturas son similares a las presentadas en el capítulo anterior, aunque con algunas modificaciones.




Figura 6.1: Sistemas artificiales utilizados para el aprendizaje.

Estos sistemas presentan un mayor número de conexiones. En el caso de la Arquitectura 1b (Fig. 6.1(a)), las conexiones adicionales se establecieron únicamente entre las interneuronas y las neuronas motoras (mostradas en rosa y verde, respectivamente). Por el contrario, en la arquitectura 2b cada neurona sensorial está conectada a las dos neuronas motoras (Fig. 6.1(b)). Las conexiones adicionales de estas arquitecturas tienen la finalidad de integrar la información sensorial proveniente del lado izquierdo del sistema con la información registrada del lado derecho. Asimismo, cada sistema presenta dos sensores de colisión, uno del lado izquierdo (c_1) y el otro del lado derecho (c_2).

Ambos sensores tienen un umbral de activación binario: el sensor c_1 se activa únicamente cuando al menos uno de los sonares del lado izquierdo (1, 2, 3 o 4) presenta una activación igual o mayor a 0.8, que equivale a una distancia de 1000 mm. Por otro lado, el sensor c_2 se activa cuando al menos uno de los sonares del lado derecho (5, 6, 7 u 8) presenta un valor igual o mayor a 0.8.

Los pesos sinápticos que participaron en el aprendizaje fueron inicializados aleatoriamente y se modificaron en cada ventana de tiempo mediante la siguiente regla de aprendizaje Hebbiano:

$$\Delta w = \eta \text{act}(n_{pre}) \cdot \text{act}(n_{post}) - \epsilon \quad (6.1)$$

donde η es la tasa de aprendizaje y ϵ la tasa de olvido, mientras que $\text{act}(n_{pre})$ y $\text{act}(n_{post})$ corresponden a la actividad de las neuronas presináptica y postsináptica, respectivamente. Durante los experimentos se consideró una tasa de aprendizaje de 0.08 y una tasa de olvido de 0.000015. Ambos valores fueron determinados experimentalmente. El valor de la tasa de olvido fue establecido tomando en cuenta que valores altos de la misma provocaban que los pesos sinápticos reforzados durante una colisión decayeran rápidamente debido al tiempo que tarda el agente en encontrarse con el siguiente obstáculo. El grado de activación de las neuronas fue normalizado en un intervalo de 0 a 1, dependiendo del número de potenciales de acción registrados en cada ventana de tiempo.

Los sistemas fueron diseñados para que cada vez que el agente choque con un obstáculo, la activación del sensor de colisión correspondiente genere que la neurona motora asociada a él dispare. De manera simultánea, las neuronas sensoriales y/o las interneuronas correspondientes serán activadas por la cercanía con el obstáculo. Las conexiones entre las neuronas sensoriales y/o interneuronas y las neuronas motoras correspondientes se reforzarán mediante la regla de aprendizaje hebbiano. El peso sináptico inicial entre las neuronas que participan en el aprendizaje fue establecido de manera tal que, al inicio de las simulaciones las neuronas motoras son activadas únicamente por el sensor de colisión correspondiente. No obstante, una vez que el sistema ha aprendido, la asociación multimodal ocurre y las neuronas motoras serán activadas por las neuronas sensoriales o interneuronas, según sea el caso, y no por los sensores de colisión. El funcionamiento de estos sistemas está inspirado en el experimento reportado por Scheier et al. (1998).

6.1. Arquitectura con interneuronas

Este experimento se realizó con el sistema cuya arquitectura neuronal presenta ocho neuronas sensoriales, dos interneuronas y dos neuronas motoras. El sistema y los valores establecidos para la simulación se especifican en la Fig. 6.2.

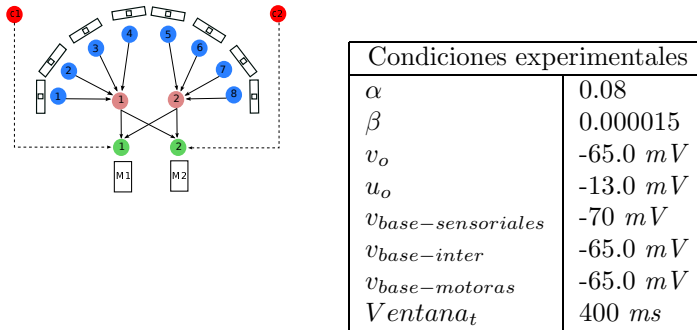


Figura 6.2: Sistema experimental 1

Los pesos sinápticos iniciales se muestran en el Cuadro 6.1. Las neuronas sensoriales se indican con una s , las interneuronas con una i y las neuronas motoras con la letra m . Los subíndices indican la posición de la neurona dentro de la red. Cada uno de los pesos sinápticos establecidos entre las neuronas sensoriales y las interneuronas tiene un valor de 0.7, el cual asegura el disparo de las interneuronas cada vez que alguna de las neuronas sensoriales a las que se encuentran conectadas dispara. Los guiones (-) indican que no hay conexión entre neuronas. El valor de conexión entre las neuronas sensoriales y las interneuronas permanece fijo durante la simulación. Los pesos sinápticos que son modulados durante el experimento se muestran en **negritas**.

La navegación del agente en el entorno durante la simulación se muestra en la Fig. 6.3. Las colisiones registradas durante el recorrido del agente se indican con una flecha y un número que marca el orden en el que se presentaron. Como se observa, durante el trayecto se registraron seis colisiones. Los sensores que registraron cada una de las colisiones, es decir, que presentaron una activación igual o mayor a 0.8, se indican en el Cuadro que acompaña a la misma figura (Fig. 6.3). Como se ha mencionado anteriormente, los sensores del 1 al 4 se ubican del lado izquierdo del agente, mientras que los sensores

		<i>Neurona</i>									
-		s_1	s_2	s_3	s_4	s_5	s_6	s_7	s_8	m_1	m_2
i_1		0.7	0.7	0.7	0.7	-	-	-	-	0.49	0.29
i_2		-	-	-	-	0.7	0.7	0.7	0.7	0.13	0.36

Cuadro 6.1: Pesos sinápticos iniciales durante el experimento 1.

del 5 al 8 corresponden al lado derecho. La información del Cuadro de la Fig. 6.3) muestra que las colisiones 1, 2 y 5 fueron registradas por sensores que se encuentran del lado izquierdo de la arquitectura, lo que indica que el sensor de colisión que se activó en estos tres casos fue el c_1 . Por lo tanto, la neurona m_1 se activó durante estas colisiones. En contraste, las colisiones 3, 4 y 6 activaron al sensor de colisión c_2 . La información de los sensores obtenida durante cada colisión también indica cuáles neuronas, ya sea sensoriales como interneuronas, están activas durante cada colisión. Es decir, si algún sensor del lado derecho se activa, la neurona sensorial asociada a él se activará y hará disparar a la interneurona a la que esté conectada directamente, debido a la proximidad con el obstáculo. Por lo tanto, la información de los sonares activos durante las colisiones se puede traducir a información de las neuronas activadas durante cada colisión.

A continuación, se muestran algunas gráficas que ilustran el potencial de membrana de las interneuronas y las neuronas motoras registrado durante cuatro diferentes situaciones del agente con su entorno, también se presenta la gráfica del cambio de los pesos sinápticos en el tiempo. Estos registros se muestran con la finalidad de ilustrar gráficamente la relación de los patrones de activación obtenidos con el cambio en los pesos sinápticos registrado en las diferentes situaciones.

Uno de los posibles patrones de activación registrados durante el experimento se muestra en la Fig.6.4 y corresponde a la actividad neuronal registrada durante la colisión 1. Como se observa, en este caso únicamente la interneurona 1 y la neurona motora 1 generan potenciales de acción. Este patrón corresponde a un incremento en el peso sináptico entre estas neuronas (Fig.6.7,número 1), mientras que los demás pesos disminuirán debido a que las otras dos neuronas no disparan durante esta colisión. Un patrón de activación similar se observará durante las colisiones 2 y 5, ya que en estos casos se activan las

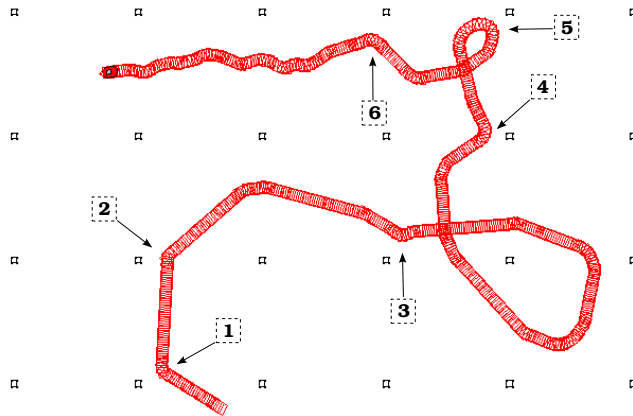


Figura A

Colisión							
Sensor	1	2	3	4	5	6	
1	Activado	Activado	-	-	Activado	-	c ₁
2	Activado	-	-	-	Activado	-	
3	-	-	-	-	Activado	-	
4	-	-	-	-	Activado	-	
5	-	-	-	-	-	-	
6	-	-	-	Activado	-	-	c ₂
7	-	-	-	Activado	-	Activado	
8	-	-	Activado	Activado	-	Activado	

Figura 6.3: Recorrido del agente artificial durante el experimento 1.

mismas neuronas que se activan en la colisión 1. El incremento en los pesos sinápticos durante estas colisiones también se indican en la Fig.6.7. Es importante recordar que los pesos sinápticos iniciales no son lo suficientemente altos como para que las interneuronas hagan disparar a las neuronas motoras. Por lo tanto, en este caso la activación de la neurona motora 1 se debe a la activación del sensor de colisión c₁ y no a la activación de la interneurona.

La Fig.6.5 muestra otro patrón de activación que es similar al anterior. Se trata del patrón de activación durante una colisión en la que ahora se activan la interneurona 2 y la neurona motora 2. Esto se verá reflejado en un aumento en el peso sináptico de estas neuronas (Fig.6.7). Los otros tres pesos sinápticos

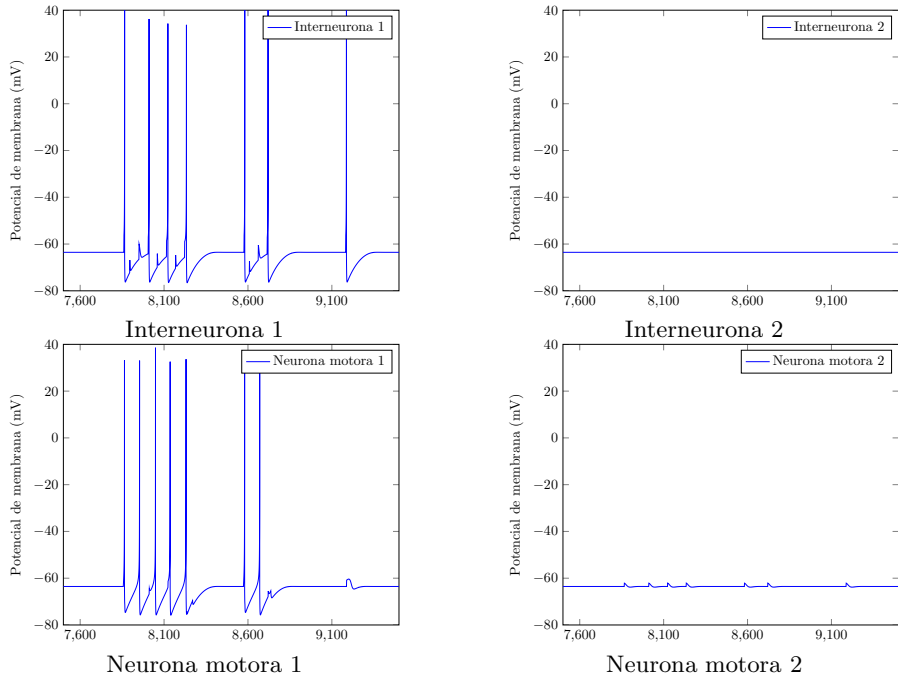


Figura 6.4: Registro de la actividad neuronal durante la Colisión 1.

no se incrementan. Este caso es similar a lo que sucede en las colisiones 4 y 6, porque se activan las mismas neuronas que en la colisión 2. Al igual que en la Fig. 6.4, la activación de la neurona motora en la Fig. 6.5 se debe a la activación del sensor de colisión y no a la actividad de la interneurona.

Otros posibles escenarios son los que involucran patrones de activación en los que las neuronas que disparan al mismo tiempo son interneuronas y neuronas motoras que se encuentran en lados opuestos de la arquitectura. Por ejemplo, cuando se activa la interneurona 1 y la neurona motora 2, o viceversa. La fig. 6.6 ilustra un patrón de activación donde las cuatro neuronas se activan.

En esta situación los cuatro pesos sinápticos incrementan, aunque en diferente proporción dependiendo del grado de actividad entre las neuronas. Por ejemplo, el peso sináptico entre la interneurona 1 y la neurona motora 1 se incrementará en mayor medida que el peso sináptico entre la misma interneu-

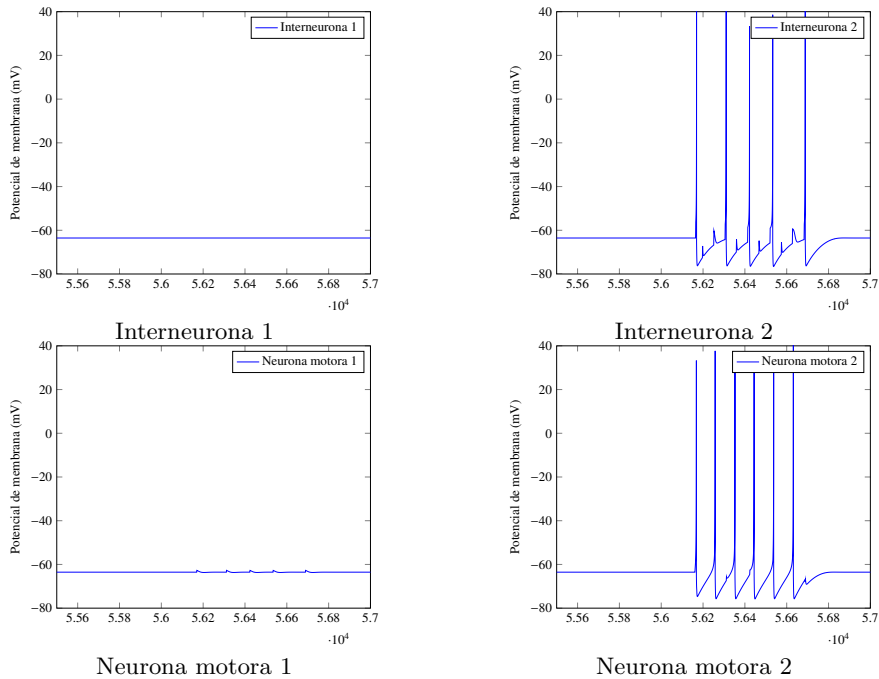


Figura 6.5: Registro de la actividad neuronal durante la Colisión 3.

rona y la neurona motora 2, debido a la menor frecuencia de disparo registrado en esta última neurona.

El patrón de activación mostrado en la Fig. 6.6 resulta más frecuente una vez que los pesos sinápticos entre las neuronas son suficientemente altos para que las interneuronas hagan disparar a las neuronas motoras. En este ejemplo, la actividad de la neurona motora 1 es producto de la actividad de la interneurona 1 y no del sensor de colisión. En contraste, la neurona motora 2 aún sigue siendo activada por el sensor de colisión c2. Es posible saber esto conociendo los valores de los pesos sinápticos (Fig. 6.7).

Existen otros patrones de activación. Sin embargo, se han mencionado únicamente aquellos que generan un incremento en el peso sináptico de al menos alguna conexión neuronal. Es decir, patrones de activación donde al menos una interneurona y una neurona motora disparen. Los demás patrones de acti-

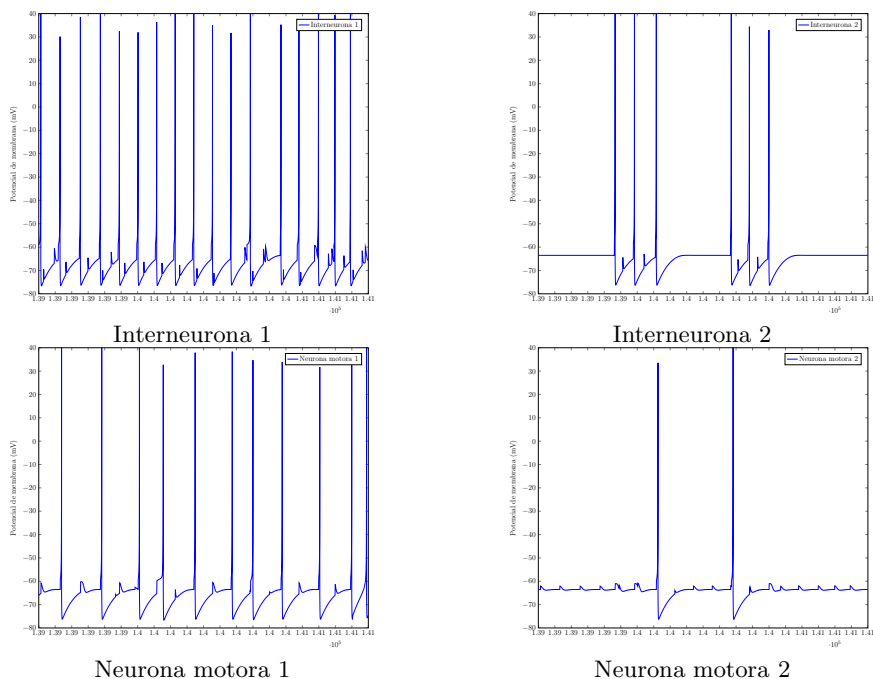


Figura 6.6: Patrón de activación simultánea de las 4 neuronas.

vación generarían olvido. Por ejemplo, cuando sólo una de las cuatro neuronas se activa no se refuerzan las conexiones. En el caso en las que las dos interneuronas se activan pero no las neuronas motoras tampoco se refuerza conexión alguna.

El cambio de los pesos sinápticos durante el experimento se muestran en la Fig.6.7. Las seis colisiones registradas durante la simulación se indican con recuadros numerados. El recuadro de cada una de las colisiones aparece cerca de la línea del peso sináptico que más varió debido a dicha colisión. Como se puede observar, se registraron cambios en los pesos sinápticos aparte de los registrados durante las colisiones. Estos cambios se producen debido a que algunas conexiones entre las interneuronas y las neuronas motoras son lo suficientemente altos como para hacer disparar a las neuronas motoras sin necesidad de que se registre una colisión. Los valores de los pesos sinápticos obtenidos al

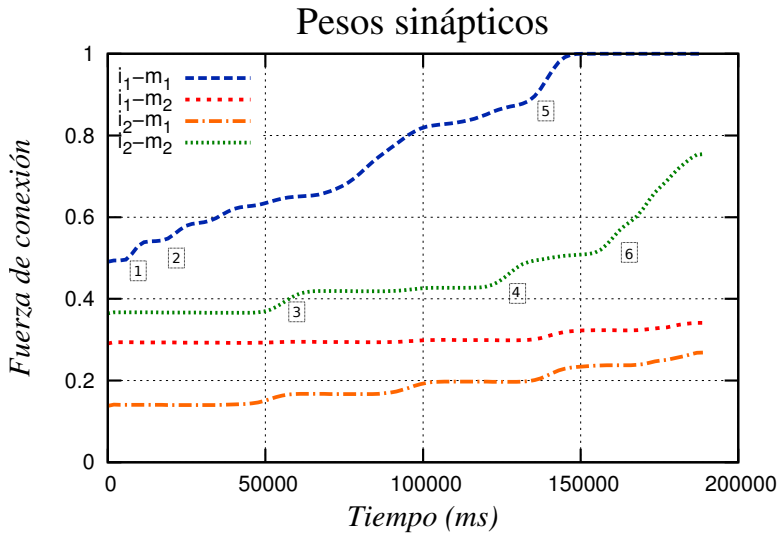


Figura 6.7: Modulación de los pesos sinápticos durante el experimento 1. Los números en recuadro indican el instante en el que ocurrió cada una de las seis colisiones.

inicio y al final de la simulación se muestran en el Cuadro 6.2.

	Pesos iniciales		Pesos finales	
	m_1	m_2	m_1	m_2
i_1	0.49	0.29	0.99	0.34
i_2	0.13	0.36	0.26	0.75

Cuadro 6.2: Pesos sinápticos iniciales y finales en el experimento 1.

Los pesos sinápticos más altos al final de la simulación corresponden a los pesos entre la interneurona 1 y la neurona motora 1, por un lado, y al peso entre la interneurona 2 y la neurona motora 2, por el otro. Ambas conexiones son mayores a 0.55, por lo que únicamente en estos casos la actividad de cada neurona motora será desencadenada por la actividad de la interneurona correspondiente y no por el sensor de colisión. La diferencia entre la activación

de una neurona motora debida al sonar de colisión y debida a la interneurona asociada a ella se ilustra en la Fig. 6.8.

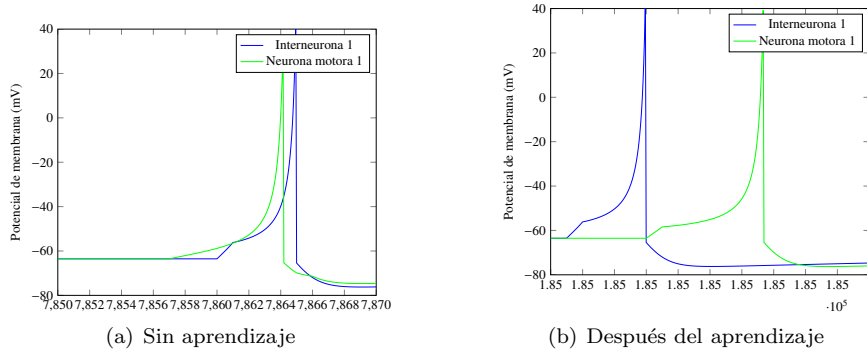


Figura 6.8: Dos tipos de activación.

Las gráficas de la Fig. 6.8 muestran un potencial de acción de la interneurona 1 y la neurona motora 1 al inicio y al final de la simulación. Durante el inicio, la conexión entre la interneurona y la neurona motora es baja. En este caso, el potencial de acción de la neurona motora es generado por el sensor de colisión $c1$ y no por la interneurona, a pesar de que esta última también dispare (Fig. 6.8(a)). Se observa que incluso la neurona motora dispara un poco antes que la interneurona. En contraste, el potencial de acción de la neurona motora será generado por la contribución de corriente que recibe de la interneurona después de que el peso sináptico entre estas dos neuronas sea reforzado (Fig. 6.8(b)). En este caso se observa que la neurona motora dispara un instante después (1ms) de que lo hace la interneurona.

La Fig. 6.9 muestra la actividad de las interneuronas y neuronas motoras con los pesos sinápticos finales. En estas gráficas se observa que la interneurona 1 y la neurona motora 1 presentan el mismo número de potenciales de acción. Esto se debe a que la neurona motora dispara siempre que la interneurona dispara, debido al peso sináptico entre ellas. En el caso de las otras dos neuronas, la neurona motora 2 no dispara siempre que dispara la interneurona 2 debido a que el peso sináptico es suficientemente alto para reproducir algunos de los potenciales de acción generados en la interneurona, pero no la totalidad de ellos.

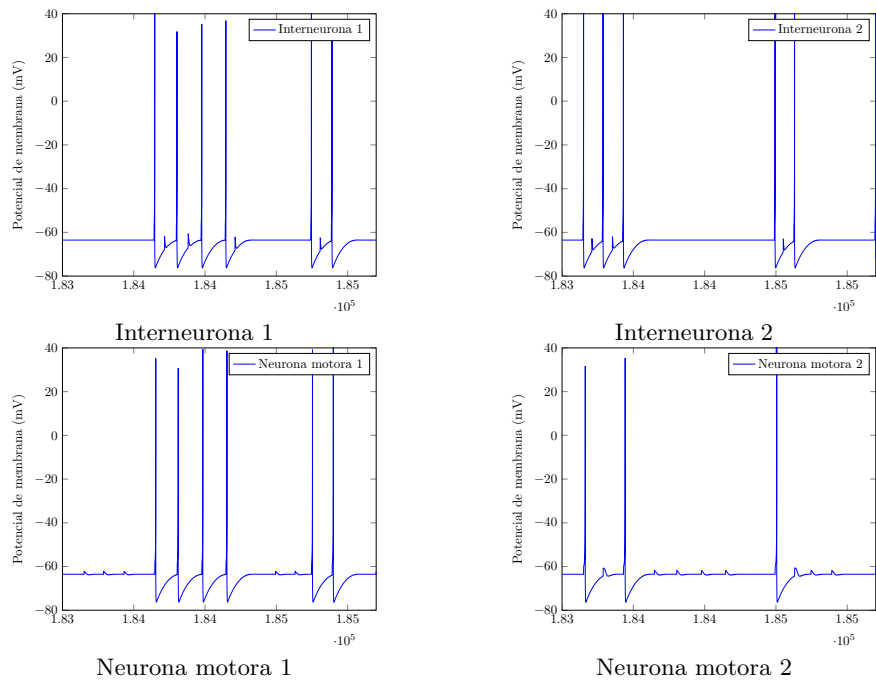


Figura 6.9: Actividad neuronal registrada después de las seis colisiones.

La navegación del agente artificial con los pesos sinápticos finales se muestra en la Fig. 6.10. En contraste con la Fig. 6.3, el agente ya no se acerca a los obstáculos y sigue una trayectoria recta.




Figura 6.10: Navegación del agente artificial después del aprendizaje.

6.2. Arquitectura completamente conectada

El experimento dos se llevó a cabo con la arquitectura de red neuronal que presenta ocho neuronas sensoriales y dos neuronas motoras. El sistema y los valores establecidos para la simulación se especifican en la Fig. 6.11.




Figura 6.11: Sistema experimental 2

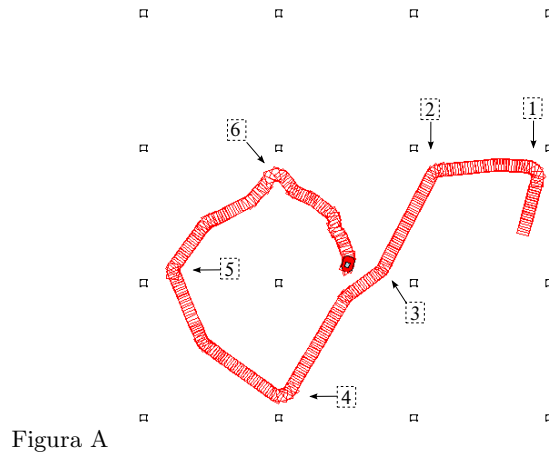
Los pesos sinápticos al inicio de la simulación se muestran en el Cuadro 6.3. En contraste con el experimento 1, en este caso todos los pesos sinápticos de la red neuronal son modulados durante la simulación.

<i>Neurona</i>								
-	s_1	s_2	s_3	s_4	s_5	s_6	s_7	s_8
m_1	0.39	0.12	0.17	0.29	0.42	0.17	0.21	0.43
m_2	0.28	0.16	0.42	0.43	0.33	0.35	0.41	0.14

Cuadro 6.3: Pesos sinápticos iniciales durante el experimento 2.

La interacción del agente con el entorno durante la simulación se muestra en la Fig. 6.3. Las colisiones registradas durante el recorrido del agente se indican con una flecha y un número que marca el orden en el que se presentaron. El número total de colisiones registradas durante el trayecto del agente es de

seis. Asimismo, los sensores que registraron cada una de las colisiones se indican en el Cuadro que acompaña a la misma figura (Fig. 6.12).



		Colisión						
Sensor	1	2	3	4	5	6		
1	-	-	Activado	Activado	Activado	Activado	c ₁	
2	-	-	-	Activado	-	-		
3	-	-	-	Activado	-	-		
4	-	-	-	Activado	-	Activado		
5	Activado	-	-	-	-	-	c ₂	
6	Activado	-	-	-	-	-		
7	Activado	Activado	-	-	-	-		
8	Activado	Activado	-	-	-	-		

Figura 6.12: Recorrido del agente artificial durante el experimento 2.

Las colisiones 1, 2 y 4 fueron registradas por los sensores del lado derecho del agente, por lo que el sensor de colisión activado durante estas colisiones fue el c₂. Mientras que las colisiones 3, 4, 5 y 6 activaron al sensor de colisión c₁. A continuación se presentan gráficas que ilustran el potencial de membrana de las neuronas sensoriales y las neuronas motoras durante dos diferentes colisiones, con la finalidad de relacionar estos patrones de activación con cambios en los pesos sinápticos entre estas neuronas. Se eligieron los patrones de activación

registrados durante la colisión 1 y la 4, ya que cada una corresponde a una colisión de uno de los lados de la arquitectura, derecha e izquierda, respectivamente.

Las gráficas de las Figuras 6.13 y 6.14 muestran la actividad neuronal durante la Colisión 1. Por un lado, la Fig. 6.13 muestra que no se registraron potenciales de acción en las neuronas del lado izquierdo de la arquitectura. En contraste, la Fig. 6.14 muestra la activación de las neuronas sensoriales 5, 6, 7 y 8, que corresponden al lado derecho de la arquitectura. Asimismo, la misma figura muestra que la única neurona motora activa durante la colisión 1 fue la neurona motora 2. Este patrón de activación tiene como resultado un incremento en el peso sináptico de las neuronas sensoriales del lado derecho de la arquitectura con la neurona motora 2, que también se encuentra del lado derecho. Este incremento en los pesos sinápticos se muestra en la Fig. 6.20. Los pesos sinápticos entre las neuronas que no se activaron durante esta colisión no varían.

Las gráficas ilustradas en las Fig. 6.15 y Fig. 6.16 muestran el patrón de activación correspondiente a la colisión 4. En estas gráficas se muestra que las neuronas sensoriales del lado izquierdo son las que ahora se activan, mientras que las neuronas sensoriales 5, 6, 7 y 8 presentan nula (muy baja activación en el caso de la neurona 8) activación. En contraste con la colisión 1, durante la colisión 4 se incrementan los pesos sinápticos de las neuronas sensoriales del lado izquierdo de la arquitectura con la neurona motora 1, que se encuentra en el mismo lado que ellas y que también se activa durante la colisión. Sin embargo, en este caso la neurona motora 2 también se activa, por lo que se incrementarán también los pesos sinápticos entre estas neuronas sensoriales y la neurona motora 2. Aunque este incremento será menor que entre las neuronas sensoriales activas y la neurona motora 1, debido a que la neurona motora 2 produjo un menor número de potenciales de acción que la neurona motora 1.

El cambio en los pesos sinápticos registrado durante este experimento se presentan de la siguiente manera: la Fig.6.17 muestra la modulación de los pesos sinápticos entre las neuronas sensoriales del lado izquierdo de la arquitectura (1, 2, 3 y 4) y la neurona motora 1. La Fig.6.18 muestra la modulación de los pesos sinápticos entre las neuronas sensoriales del lado derecho de la arquitectura (5, 6, 7 y 8) y la neurona motora 1. Por otro lado, la Fig. 6.19 muestra el cambio en los pesos sinápticos establecidos entre las neuronas sensoriales del lado izquierdo de la arquitectura con la neurona motora 2, mientras que la Fig. 6.20 muestra los pesos sinápticos de esta misma neurona con las neuronas sensoriales 5, 6, 7 y 8.

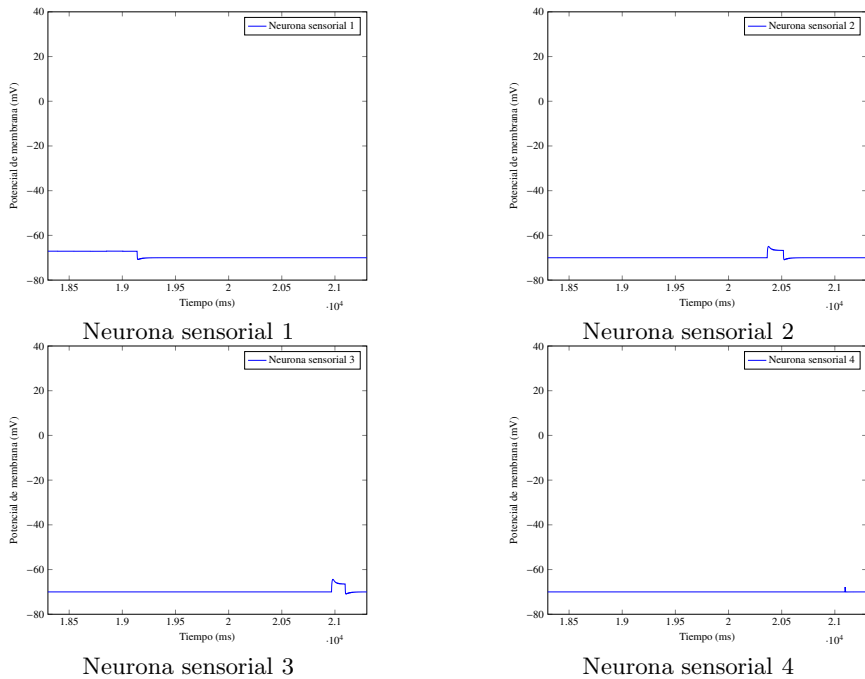


Figura 6.13: Actividad neuronal (lado izquierdo) durante la Colisión 1.

En estas gráficas podemos observar que los pesos sinápticos más altos corresponden a los pesos entre la neurona motora 1 con las neuronas sensoriales 1, 3, 4 y 8; y los pesos sinápticos de la neurona motora 2 con las neuronas sensoriales 1, 5, 6 y 7.

El recorrido del agente artificial con los pesos sinápticos obtenidos al final de la simulación se muestran en la Fig. 6.21. El agente sigue acercándose a los obstáculos debido a que algunos pesos sinápticos que transmiten información de ambos lados de la arquitectura incrementaron durante el aprendizaje. Una vez que los obstáculos son detectados por una neurona que presenta un peso sináptico fuerte con la neurona motora que se encuentra del mismo lado que ella, el agente evade el obstáculo.

<i>Neurona</i>								
-	s_1	s_2	s_3	s_4	s_5	s_6	s_7	s_8
m_1	1.0	0.26	0.60	0.80	0.42	0.16	0.21	0.89
m_2	0.32	0.20	0.99	0.47	0.59	0.40	0.87	0.45

Cuadro 6.4: Pesos sinápticos finales del experimento 2.

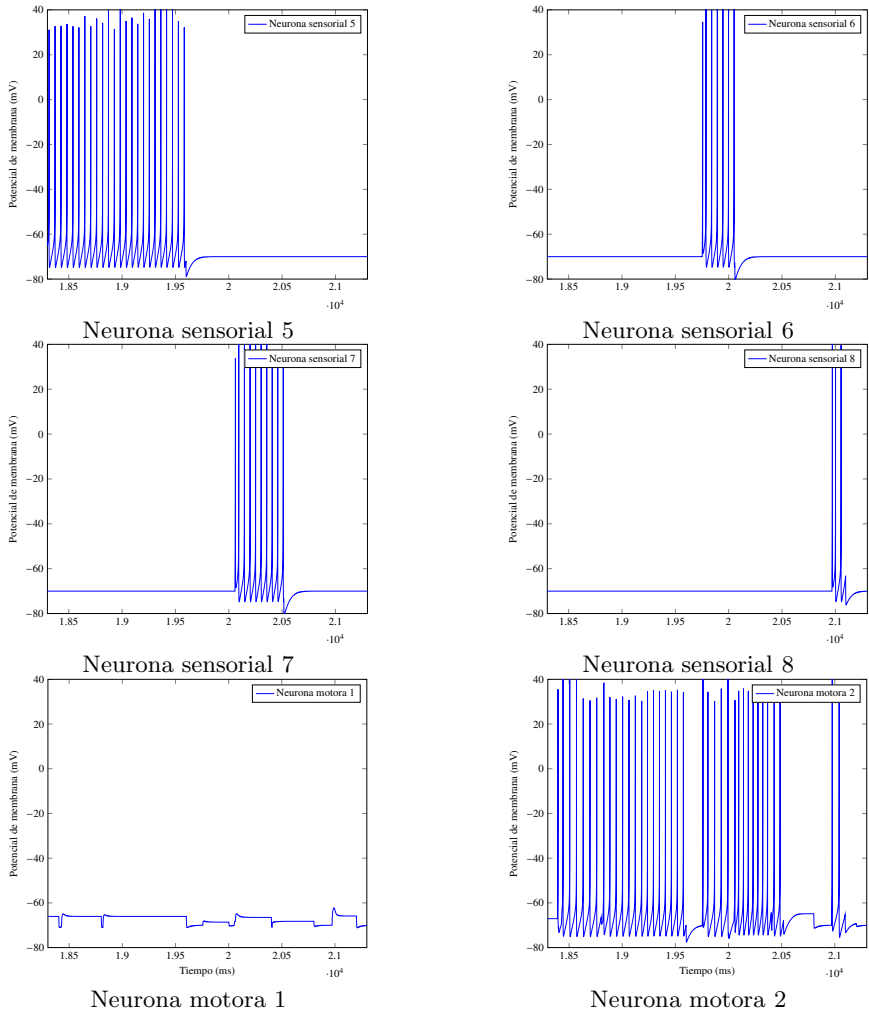


Figura 6.14: Actividad neuronal (lado derecho) durante la Colisión 1.

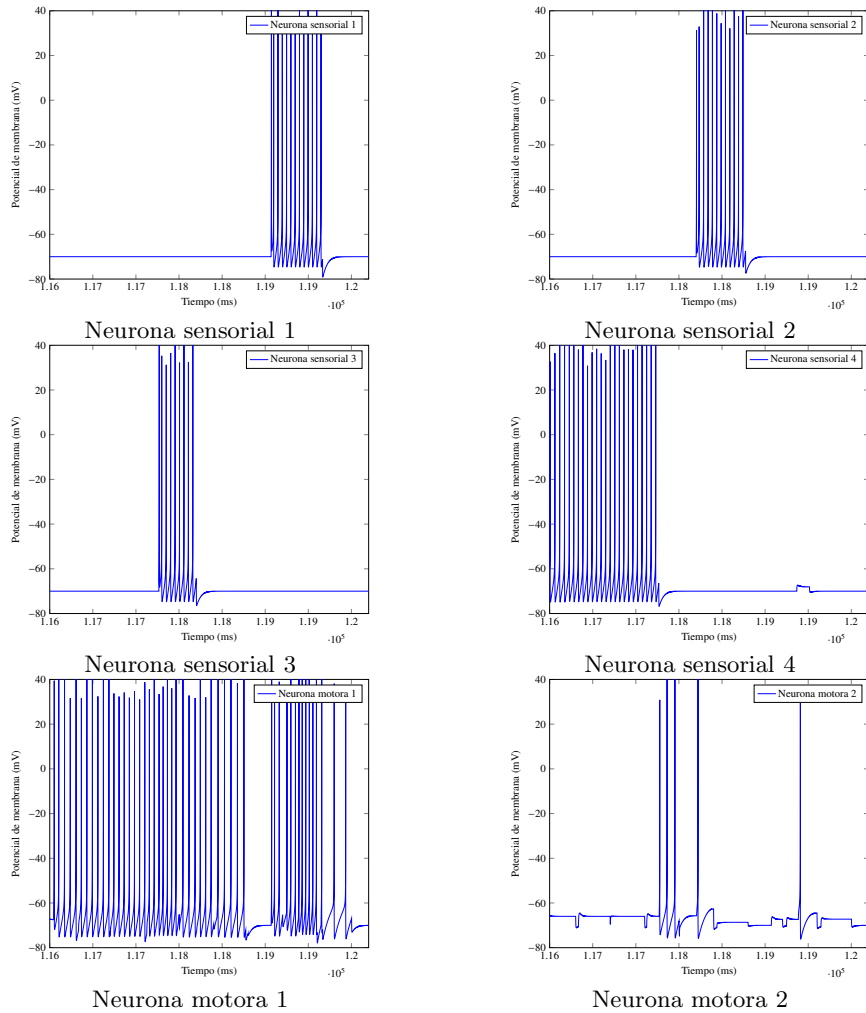


Figura 6.15: Actividad neuronal (lado izquierdo) durante la Colisión 4.

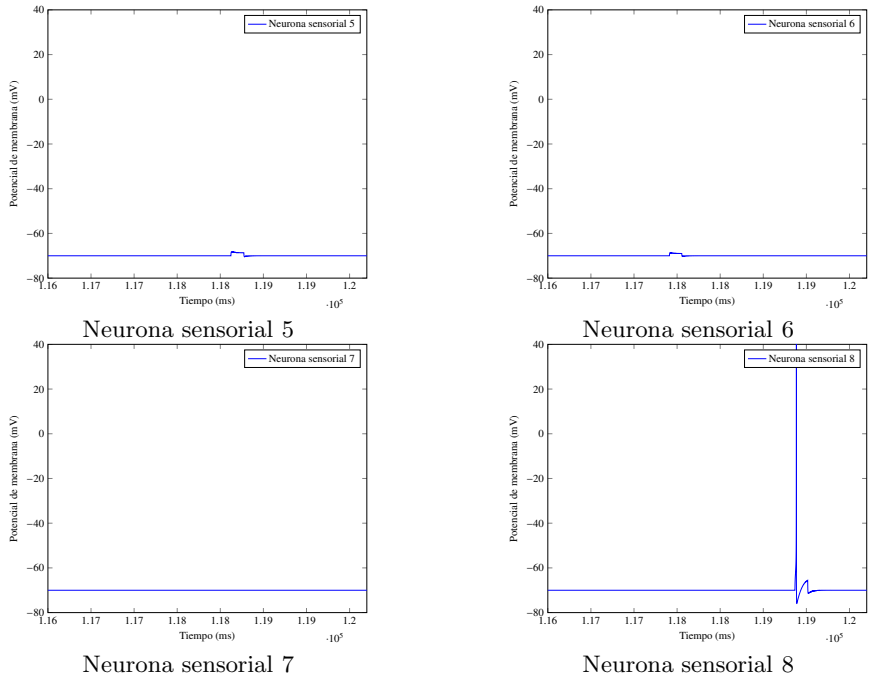


Figura 6.16: Actividad neuronal (lado derecho) durante la Colisión 4.




Figura 6.17: Modulación de los pesos sinápticos durante el experimento 2.




Figura 6.18: Modulación de los pesos sinápticos durante el experimento 2.




Figura 6.19: Modulación de los pesos sinápticos durante el experimento 2.

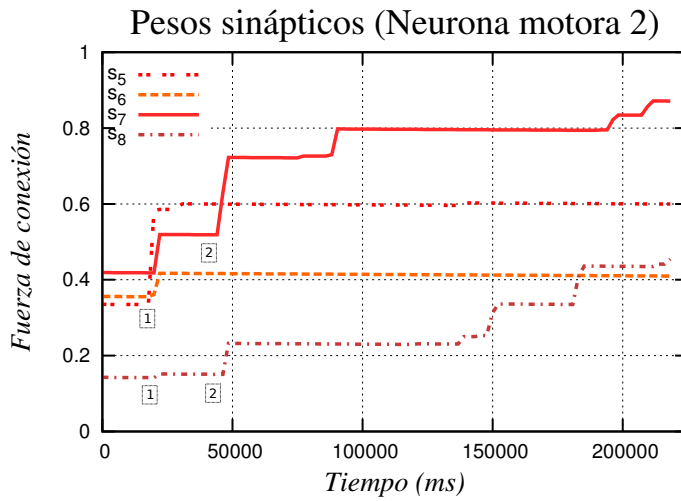


Figura 6.20: Modulación de los pesos sinápticos durante el experimento 2.

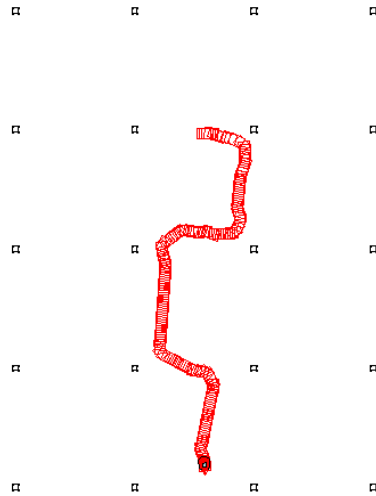


Figura 6.21: Recorrido del agente con los pesos sinápticos finales.

CAPÍTULO 7

Conclusiones

En este proyecto se realizaron simulaciones de un proceso de aprendizaje de evasión de obstáculos de un agente artificial controlado mediante redes neuronales artificiales de potenciales de acción. Las preguntas de investigación del presente proyecto, expuestas en la parte introductoria de la tesis, se responden a continuación con base en los resultados obtenidos en los experimentos:

- ¿Es posible simular un proceso de aprendizaje en una red neuronal artificial de potenciales de acción?

Las redes neuronales artificiales de potenciales de acción resultan ser modelos útiles para el estudio de procesos como el aprendizaje. En el presente trabajo se exploró el modelo de neurona de potenciales de acción propuesto por Izhikevich et al. (2003) debido a su plausibilidad biológica y eficiencia computacional. Durante los experimentos se probaron dos arquitecturas neuronales distintas. Cada una de ellas presenta ocho neuronas sensoriales y dos neuronas motoras. Sin embargo, una de las redes presenta además dos interneuronas. Los resultados de las simulaciones muestran que fue posible registrar un cambio en el comportamiento del agente artificial antes y después de implementar el aprendizaje hebbiano en ambas arquitecturas.

- ¿Es posible simular un proceso de asociación multimodal en una red neuronal artificial de potenciales de acción?

La estrategia de aprendizaje utilizada durante los experimentos es la principal contribución de esta tesis. Los pesos sinápticos establecidos entre las neuronas de las redes artificiales fueron modificados a partir de la implementación de la regla de Hebb durante un proceso de asociación

multimodal. Para poder simular el proceso de asociación multimodal se utilizaron ocho sensores de proximidad y dos sensores de colisión. Los sensores de proximidad presentan una función de activación continua y están asociados a las neuronas sensoriales. Por otro lado, los sensores de colisión tienen un umbral de activación binario y están asociados a las neuronas motoras.

Los pesos sinápticos fueron establecidos de tal manera que, al inicio de las simulaciones la activación de las neuronas motoras depende únicamente de los sensores de colisión. Sin embargo, cada vez que ocurre una colisión, el sistema asocia la información proveniente de los sensores de proximidad con la información de los sensores de colisión. Por lo tanto, el peso sináptico entre las neuronas sensoriales (o interneuronas) y las neuronas motoras que disparen simultáneamente se incrementará. Cuando la conexión entre las neuronas sensoriales (o interneuronas) y las neuronas motoras sea lo suficientemente fuerte, entonces la activación de las neuronas motoras dependerá únicamente de las interneuronas o neuronas sensoriales correspondientes y no de los sensores de colisión.

- ¿El proceso de asociación multimodal puede ser capaz de generar un comportamiento coherente en un agente artificial?

Como se ha mencionado anteriormente, fue posible registrar un cambio en el comportamiento del agente artificial antes y después de implementar el aprendizaje hebbiano en ambas arquitecturas. No obstante, el cambio conductual que exhibe cada uno de los sistemas al final de la simulación es distinto. En el caso del sistema que presenta las dos interneuronas adicionales, se observa que el agente se acerca más a los obstáculos al inicio de la simulación. Sin embargo, cuando el patrón de conexiones que permite la evasión de los obstáculos se ha establecido en la red neuronal, el agente no tiene que estar muy cerca de éstos para poder evadirlos, por lo que permanece alejado de ellos hacia el final de la simulación.

El segundo sistema, en el cual las neuronas sensoriales están completamente conectadas con las neuronas motoras, exhibe un comportamiento inicial similar al del primer sistema. Sin embargo, el agente que es controlado con esta red neuronal exhibe un comportamiento final más *explorador* que el primer sistema. En este caso, el comportamiento del agente presenta la característica de poder acercarse más a los obstáculos

antes de evadirlos. Este comportamiento no era el esperado, ya que se pensaba obtener un patrón de conexión neuronal que originara un comportamiento parecido al exhibido por el primer sistema. Sin embargo, sólo algunos de los pesos sinápticos incrementaron en la forma en que se esperaba. Los pesos sinápticos que corresponden a este comportamiento *explorador* son aquellos que relacionan la información sensorial registrada de uno de los lados de la arquitectura con el motor del lado opuesto.

Una explicación de los resultados obtenidos es que el número de colisiones registradas durante las simulaciones afecta de manera distinta el aprendizaje de cada sistema. El valor de las conexiones en el sistema con interneuronas cambia rápidamente debido a que cada interneurona está asociada a cuatro neuronas sensoriales, por lo que no importa qué neurona sensorial se active para incrementar el peso sináptico entre la interneurona y la neurona motora correspondientes. Sin embargo, para que el valor de las conexiones en el segundo sistema sea el idóneo para evadir los obstáculos de forma similar que el primer sistema, cada neurona sensorial debe registrar al menos una colisión, dependiendo del peso sináptico inicial.

Finalmente y basándonos en los resultados de este proyecto, creemos que la simulación de procesos cognitivos en redes neuronales artificiales embebidas puede ser de gran interés para el desarrollo de sistemas que controlen agentes artificiales mediante cultivos de neuronas biológicas *in vitro*.

Bibliografía

- Bliss, T. V., Collingridge, G. L., et al. (1993). A synaptic model of memory: long-term potentiation in the hippocampus. *Nature*, 361(6407):31–39.
- Brooks, R. A. (1991). Intelligence without representation. *Artificial intelligence*, 47(1):139–159.
- Caporale, N. and Dan, Y. (2008). Spike timing-dependent plasticity: a hebbian learning rule. *Annu. Rev. Neurosci.*, 31:25–46.
- Copeland, J. (1993). *Artificial Intelligence: A Philosophical Introduction*. Wiley.
- DeMarse, T. B., Wagenaar, D. A., Blau, A. W., and Potter, S. M. (2001). The neurally controlled animat: biological brains acting with simulated bodies. *Autonomous robots*, 11(3):305–310.
- Dreyfus, H. L. (1967). Why computers must have bodies in order to be intelligent. *The Review of Metaphysics*, pages 13–32.
- Dreyfus, H. L. (1972). What computers can't do.
- Feldman, D. E. (2012). The spike-timing dependence of plasticity. *Neuron*, 75(4):556–571.
- Freeman, S. and Hamilton, H. (2005). Biological science.
- Gross, R. D. and Humphreys, P. (1992). *Psychology: The science of mind and behaviour*. Hodder & Stoughton London.
- Hebb, D. O. (2002). *The organization of behavior: A neuropsychological theory*. Psychology Press.
- Hodgkin, A. L. and Huxley, A. F. (1939). Action potentials recorded from inside a nerve fibre. *Nature*, 144(3651):710–711.
- Hodgkin, A. L. and Katz, B. (1949). The effect of sodium ions on the electrical activity of the giant axon of the squid. *The Journal of physiology*, 108(1):37.

- Izhikevich, E. M. (2004). Which model to use for cortical spiking neurons? *IEEE transactions on neural networks*, 15(5):1063–1070.
- Izhikevich, E. M. (2007). *Dynamical systems in neuroscience*. MIT press.
- Izhikevich, E. M. et al. (2003). Simple model of spiking neurons. *IEEE Transactions on neural networks*, 14(6):1569–1572.
- Izhikevich, E. M., Gally, J. A., and Edelman, G. M. (2004). Spike-timing dynamics of neuronal groups. *Cerebral cortex*, 14(8):933–944.
- Kandel, E. R., Schwartz, J. H., Jessell, T. M., et al. (2000). *Principles of neural science*, volume 4. McGraw-Hill New York.
- Kleim, J. A. and Jones, T. A. (2008). Principles of experience-dependent neural plasticity: implications for rehabilitation after brain damage. *Journal of Speech, Language, and Hearing Research*, 51(1):S225–S239.
- Maass, W. (1997). Networks of spiking neurons: the third generation of neural network models. *Neural networks*, 10(9):1659–1671.
- Manson, N. C. (2004). Brains, vats, and neurally-controlled animats. *Studies in History and Philosophy of Science Part C: Studies in History and Philosophy of Biological and Biomedical Sciences*, 35(2):249–268.
- McCarthy, J., Minsky, M. L., Rochester, N., and Shannon, C. E. (2006). A proposal for the dartmouth summer research project on artificial intelligence, august 31, 1955. *AI Magazine*, 27(4):12.
- Mingers, J. (2001). Embodying information systems: the contribution of phenomenology. *Information and organization*, 11(2):103–128.
- Mokhtar, M., Halliday, D. M., and Tyrrell, A. M. (2007). Autonomous navigational controller inspired by the hippocampus. In *Neural Networks, 2007. IJCNN 2007. International Joint Conference on*, pages 813–818. IEEE.
- Moravec, H. (1984). Locomotion, vision and intelligence.
- Newell, A. and Simon, H. A. (1976). Computer science as empirical inquiry: Symbols and search. *Communications of the ACM*, 19(3):113–126.

- Novellino, A., D'Angelo, P., Cozzi, L., Chiappalone, M., Sanguineti, V., and Martinoia, S. (2007). Connecting neurons to a mobile robot: an in vitro bidirectional neural interface. *Computational intelligence and neuroscience*, 2007.
- Pfeifer, R. and Scheier, C. (1999). *Understanding intelligence*. MIT press.
- Potter, S. M. (2001). Distributed processing in cultured neuronal networks. *Progress in brain research*, 130:49–62.
- Potter, S. M. (2007). What can ai get from neuroscience? In *50 years of artificial intelligence*, pages 174–185. Springer.
- Potter, S. M. and DeMarse, T. B. (2001). A new approach to neural cell culture for long-term studies. *Journal of neuroscience methods*, 110(1):17–24.
- Reece, J. B., Urry, L. A., Cain, M. L., Wasserman, S. A., Minorsky, P., Jackson, R. B., et al. (2011). *Campbell biology*. Pearson Boston.
- Scheier, C., Pfeifer, R., and Kuniyoshi, Y. (1998). Embedded neural networks: exploiting constraints. *Neural Networks*, 11(7):1551–1569.
- Siegelbaum, S. A. and Kandel, E. R. (1991). Learning-related synaptic plasticity: Ltp and ltd. *Current opinion in neurobiology*, 1(1):113–120.
- Trhan, P. (2012). The application of spiking neural networks in autonomous robot control. *Computing and Informatics*, 29(5):823–847.
- Verhoog, M. B., Goriounova, N. A., Obermayer, J., Stroeder, J., Hjorth, J. J., Testa-Silva, G., Baayen, J. C., de Kock, C. P., Meredith, R. M., and Mansvelder, H. D. (2013). Mechanisms underlying the rules for associative plasticity at adult human neocortical synapses. *The Journal of Neuroscience*, 33(43):17197–17208.
- Xydas, D., Norcott, D. J., Warwick, K., Whalley, B. J., Nasuto, S. J., Becerra, V. M., Hammond, M. W., Downes, J., and Marshall, S. (2008). Architecture for neuronal cell control of a mobile robot. In *European Robotics Symposium 2008*, pages 23–31. Springer.